

Akademia Bialska im. Jana Pawła II



AI 360°:

INNOWACJE I ZASTOSOWANIA SZTUCZNEJ INTELIGENCJI W GOSPODARCE, SPOŁECZEŃSTWIE I NAUCE

Redakcja naukowa
Agnieszka Siedlecka
Mariusz Pyra

Biała Podlaska 2026

Akademia Bialska im. Jana Pawła II

**AI 360°:
innowacje i zastosowania sztucznej
inteligencji w gospodarce,
społeczeństwie i nauce**

Redakcja naukowa

Agnieszka Siedlecka

Mariusz Pyra

Biała Podlaska 2026

Wydawca
Akademia Bialska im. Jana Pawła II

Recenzja
dr inż. Tomasz Grudniewski
dr inż. Marta Chodyka
dr Marcin Wroński

Projekt „AI 360°: INNOWACJE, PRZEMYSŁ, SPOŁECZEŃSTWO,
NAUKA” dofinansowany ze środków budżetu państwa, przyznanych przez
Ministra Nauki w ramach Programu Doskonała Nauka II, zgodnie z umową
nr KONF/SP/0106/2024/02

© Copyright by Akademia Bialska im. Jana Pawła II



Książka jest udostępniana na licencji Creative Commons Uznanie
autorstwa – Użycie niekomercyjne – Bez utworów zależnych 4.0
Międzynarodowa

ISBN 978-83-68103-36-6
<https://doi.org/10.29316/9788368103366>



Wydawnictwo AB JP II
ul. Sidorska 95/97
21-500 Biała Podlaska
wydawnictwo.akademibialska.pl

Projekt okładki oraz skład

druk-24h.com.pl
DRUKARNIA CYFROWA

Hurtowa 21, 15-399 Białystok
tel. 535 500 898
e-mail: studio@druk-24h.com.pl

SPIS TREŚCI

Wstęp	5
Katarzyna Szymańska	
Robotyzacja i sztuczna inteligencja w gospodarce – korzyści i zagrożenia w sektorze prywatnym i państwowym	8
Władysław Blocki	
Algorytmy grafowe w erze sztucznej inteligencji: inteligentne rozwiązania dla informatyki	21
Katarzyna Łącka, Agnieszka Holonowicz	
Integracja AI i zrównoważonego rozwoju – perspektywy i wyzwania w rolnictwie	44
Barbara Jantos, Michał Wierzbicki, Michał Tomaszewski	
Applications and limitations of artificial intelligence methods in personalized rehabilitation therapy	54
Robert Lizak	
Bariery wykorzystania AI w redukcji erozji bazy podatkowej CIT w Polsce na tle kontroli NIK	75
Julia Grochowska, Marcin Weiner	
Zastosowanie uczenia maszynowego do wczesnej detekcji stresu u pomidorów (<i>Solanum lycopersicum</i>) w uprawach szklarniowych na podstawie wydzielanych lotnych związków organicznych	96

Janusz Zemła

Wdrożenie systemu wizyjnego opartego na sztucznej inteligencji
w kontroli jakości produktu – studium przypadku z Helvoet Polska 119

Wiktor Kolat, Wiktoria Galecka, Wiktor Kowalski

Porównanie regresji liniowej (dynamicznej AR(2)-X) i sieci
neuronowych w prognozowaniu cen nieruchomości mieszkaniowych
w Polsce – analiza na danych kwartalnych 2014-2024 135

Martyna Wróbel, Wiktor Sędkowski

Przegląd technik haszowania w zabezpieczaniu modeli AI
i rozpoznawaniu ataków typu data poisoning przy użyciu detekcji kolizji
haszy 161

Joanna Nowicka

Od projektu do szwu. Zastosowanie AI w krawiectwie 181

WSTĘP

Sztuczna inteligencja stała się jednym z kluczowych czynników współczesnej transformacji społeczno-gospodarczej. Jej rozwój wykracza obecnie poza obszar informatyki i zaawansowanych rozwiązań cyfrowych, obejmując coraz szersze spektrum zastosowań w gospodarce, administracji publicznej, medycynie, edukacji, rolnictwie, logistyce, przemyśle, usługach oraz działalności twórczej. Wraz z rosnącą dostępnością narzędzi opartych na AI pojawiają się zarówno nowe możliwości zwiększania efektywności, automatyzacji procesów, personalizacji usług i wspomagania decyzji, jak również pytania o bezpieczeństwo, odpowiedzialność, jakość danych, kompetencje użytkowników oraz społeczne skutki wdrażania inteligentnych systemów.

Znaczenie sztucznej inteligencji polega nie tylko na jej potencjale technologicznym, lecz także na zdolności do przekształcania relacji między człowiekiem, organizacją i technologią. AI coraz częściej staje się elementem codziennych procesów decyzyjnych, produkcyjnych, diagnostycznych i analitycznych. Wymaga to nie tylko rozwoju narzędzi informatycznych, ale również pogłębionej refleksji nad warunkami ich odpowiedzialnego wykorzystania. Szczególnie istotne pozostaje pytanie o to, w jaki sposób sztuczna inteligencja może wspierać rozwój gospodarki i społeczeństwa, nie prowadząc jednocześnie do pogłębiania nierówności kompetencyjnych, marginalizacji wybranych grup zawodowych czy niekontrolowanego wzrostu zależności od technologii.

Monografia stanowi próbę wieloaspektowego spojrzenia na sztuczną inteligencję jako zjawisko interdyscyplinarne. Zebrane w niej rozdziały ukazują AI zarówno z perspektywy technologicznej, jak i społecznej, ekonomicznej oraz organizacyjnej. Autorzy analizują m.in. robotyzację i sztuczną inteligencję w gospodarce, algorytmy grafowe, zastosowania AI w rolnictwie i zrównoważonej produkcji rolnej, wykorzystanie metod sztucznej inteligencji w rehabilitacji, administracji podatkowej, prognozowaniu cen nieruchomości,

bezpieczeństwie modeli AI i ochronie integralności danych, a także w kontroli jakości w przedsiębiorstwie produkcyjnym oraz w tradycyjnych sektorach usługowo-rzemieślniczych, takich jak krawiectwo. Taki układ tomu pozwala pokazać, że AI nie jest już wyłącznie domeną informatyki, lecz staje się narzędziem zmieniającym sposób funkcjonowania wielu branż, instytucji i grup zawodowych.

Wspólnym mianownikiem rozdziałów zamieszczonych w monografii jest przekonanie, że sztuczna inteligencja nie powinna być rozpatrywana wyłącznie jako narzędzie automatyzacji. Jej znaczenie ujawnia się przede wszystkim tam, gdzie pozwala lepiej wykorzystywać dane, wspierać procesy decyzyjne, ograniczać ryzyko błędów, tworzyć nowe modele usług i produkcji oraz rozwijać kompetencje człowieka. Jednocześnie prezentowane rozdziały pokazują, że wdrażanie AI wymaga ostrożności, wiedzy, odpowiednich standardów bezpieczeństwa, transparentności modeli oraz świadomości ograniczeń metod analitycznych i technologicznych.

Monografia powstała jako rezultat konferencji naukowej „AI 360°: Innowacje, przemysł, społeczeństwo, nauka”, zorganizowanej przez Akademię Białską im. Jana Pawła II. Konferencja została pomyślana jako forum wymiany wiedzy, doświadczeń i dobrych praktyk pomiędzy przedstawicielami nauki, biznesu, administracji, instytucji publicznych, studentami, doktorantami oraz osobami zainteresowanymi problematyką sztucznej inteligencji. Jej założeniem było stworzenie przestrzeni do dyskusji nad praktycznymi zastosowaniami AI, wyzwaniem wdrożeniowymi, społecznymi i etycznymi konsekwencjami rozwoju tej technologii oraz kierunkami dalszych badań.

W monografii zamieszczono wybrane opracowania przygotowane na podstawie referatów zgłoszonych i zaprezentowanych podczas konferencji. Nie wyczerpują one pełnego zakresu problematyki podejmowanej w trakcie obrad, lecz stanowią reprezentatywny wybór zagadnień ukazujących interdyscyplinarny charakter współczesnych badań nad sztuczną inteligencją. Część pozostałych wystąpień i wniosków konferencyjnych przewidziano do upowszechnienia w innych formach publikacyjnych, w tym w czasopiśmie naukowych Akademii Białskiej im. Jana Pawła II.

Publikacja monografii wpisuje się w cele konferencji, wśród których znalazły się: upowszechnianie wiedzy o sztucznej inteligencji, prezentacja badań i praktycznych rozwiązań, identyfikacja barier wdrożeniowych, promowanie

interdyscyplinarnego podejścia do AI oraz wspieranie odpowiedzialnego korzystania z nowych technologii. Z tego względu monografia nie ma charakteru jednorodnego podręcznika, lecz stanowi zbiór opracowań ukazujących różne perspektywy badawcze i praktyczne. Taka konstrukcja odpowiada samej naturze sztucznej inteligencji, która rozwija się na styku wielu dyscyplin, sektorów i obszarów zastosowań.

Redaktorzy monografii składają podziękowania wszystkim Autorom, Recenzentom oraz Uczestnikom konferencji naukowej „AI 360°: innowacje, przemysł, społeczeństwo, nauka”, których aktywność naukowa i udział w dyskusji przyczyniły się do powstania niniejszej publikacji. Szczególne podziękowania kierowane są do członków Komitetu Naukowego i Komitetu Organizacyjnego konferencji, Sekretariatu Konferencji oraz osób zaangażowanych w przygotowanie wydarzenia i proces wydawniczy. Redaktorzy wyrażają również wdzięczność Patronom Honorowym konferencji: JM Rektorowi Akademii Bialskiej im. Jana Pawła II prof. dr. hab. Jerzemu Nitychorukowi, Białkopodlaskiej Izbie Gospodarczej oraz Związkowi Przedsiębiorców i Pracodawców Podlasie.

Konferencja oraz działania z nią związane zostały zrealizowane przy wsparciu finansowym ze środków Ministra Nauki w ramach programu „Doskonała Nauka II – Wsparcie konferencji naukowych”. Dofinansowanie to umożliwiło organizację wydarzenia, upowszechnienie jego rezultatów oraz przygotowanie monografii, która stanowi trwały efekt naukowy podjętej debaty nad rolą sztucznej inteligencji we współczesnej gospodarce, społeczeństwie, technologii i nauce.

dr hab. Agnieszka Siedlecka, prof. uczelni
dr Mariusz Pyra

dr Katarzyna Szymańska¹

Państwowa Akademia Nauk Stosowanych im. Ignacego Mościckiego w Ciechanowie

ROBOTYZACJA I SZTUCZNA INTELIGENCJA W GOSPODARCE – KORZYŚCI I ZAGROŻENIA W SEKTORZE PRYWATNYM I PAŃSTWOWYM

ROBOTICS AND ARTIFICIAL INTELLIGENCE IN THE ECONOMY – BENEFITS AND RISKS IN THE PRIVATE AND PUBLIC SECTORS

Streszczenie

Celem rozdziału jest przedstawienie wyników analizy wpływu robotyzacji i sztucznej inteligencji (ang. *artificial intelligence* – AI) na transformację współczesnej gospodarki, z uwzględnieniem specyfiki funkcjonowania sektora prywatnego oraz publicznego. W pierwszej części rozdziału dokonano konceptualizacji kluczowych pojęć. Zasadniczą część opracowania skoncentrowano na identyfikacji głównych korzyści płynących z implementacji sztucznej inteligencji i robotyzacji – takich jak wzrost efektywności operacyjnej, redukcja kosztów, poprawa jakości usług publicznych i komercyjnych – oraz na wskazaniu fundamentalnych zagrożeń. Szczególną uwagę poświęcono zagadnieniom cyberbezpieczeństwa, postrzeganego jako warunek zrównoważonego i bezpiecznego rozwoju technologii inteligentnych. Przeprowadzona analiza przypadków wdrożeń w sektorze przemysłowym, administracyjnym oraz usługowym umożliwiła identyfikację czynników sukcesu i porażki projektów opartych na AI. Wnioski wskazują na konieczność prowadzenia spójnej, wielowymiarowej polityki transformacyjnej, łączącej innowacyjność z odpowiedzialnością społeczną i bezpieczeństwem

¹ <https://orcid.org/0000-0003-4131-2484>, e-mail: katarzyna.szymanska@pansim.edu.pl
Szymańska, K. (2026). Robotyzacja i sztuczna inteligencja w gospodarce – korzyści i zagrożenia w sektorze prywatnym i państwowym. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 8-20). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_1

systemowym, co jest niezbędne do pełnego wykorzystania potencjału AI i robotyzacji w warunkach współczesnych wyzwań cywilizacyjnych.

Słowa kluczowe: sztuczna inteligencja, robotyzacja, cyberbezpieczeństwo

Abstract

The aim of this chapter is to analyze the impact of robotics and artificial intelligence (AI) on the transformation of the contemporary economy, taking into account the specific characteristics of both the private and public sectors. The first part of the study offers a conceptual framework and defines key terms. The core sections focus on identifying the main benefits of AI and robotics implementation, such as increased operational efficiency, cost reduction, and improved quality of public and commercial services, as well as highlighting critical risks. Particular attention is paid to cybersecurity, understood as a prerequisite for the sustainable and safe development of intelligent technologies. The analysis of implementation case studies in the industrial, administrative, and service sectors has enabled the identification of key success and failure factors in AI-based projects. The findings underscore the need for a coherent, multidimensional transformation policy that integrates innovation with social responsibility and systemic security. Such an approach is essential for fully leveraging the potential of AI and robotics in the context of today's complex civilizational challenges.

Keywords: artificial intelligence, robotics, cybersecurity

Wstęp

Postępująca cyfryzacja przyczyniła się do dynamicznego rozwoju robotyzacji, automatyzacji oraz sztucznej inteligencji, które stają się integralną częścią wielu sektorów gospodarki. Procesy te mają charakter transformacyjny, wpływają nie tylko na sposób funkcjonowania przedsiębiorstw i instytucji publicznych, lecz także na strukturę rynku pracy, modele zarządzania oraz relacje społeczne. Robotyzacja i AI są obecnie uznawane za jedne z kluczowych czynników napędzających tzw. czwartą rewolucję przemysłową (Przemysł 4.0), a ich znaczenie stale rośnie zarówno w sektorze prywatnym, jak i państwowym (Schwab, 2016). Z jednej strony technologie te niosą ze sobą szereg korzyści: zwiększenie wydajności, automatyzację powtarzalnych zadań, poprawę jakości usług czy lepsze wykorzystanie danych w procesach decyzyjnych. Z drugiej strony pojawiają się liczne wyzwania i zagrożenia, takie jak ryzyko utraty

miejsce pracy, pogłębiające się wykluczenie cyfrowe, problemy etyczne oraz obawy związane z nadmierną automatyzacją procesów administracyjnych i decyzyjnych (Bostrom, 2014, s.10).

Celem niniejszej publikacji jest przedstawienie wyników analizy potencjalnych korzyści oraz zagrożeń wynikających z wdrażania robotyzacji i sztucznej inteligencji w gospodarce, ze szczególnym uwzględnieniem różnic pomiędzy sektorem prywatnym a państwowym. Zidentyfikowano główne obszary zastosowań tych technologii, a także wyjaśniono ich wpływ na funkcjonowanie instytucji, pracowników oraz społeczeństwa jako całości. W opracowaniu wykorzystano aktualną literaturę przedmiotu, wybrane raporty branżowe oraz przykłady praktycznych wdrożeń z różnych sektorów.

Robotyzacja i AI – ogólna charakterystyka

Dynamiczny rozwój technologii cyfrowych, obserwowany na przestrzeni ostatnich dekad, doprowadził do gwałtownego wzrostu znaczenia takich obszarów jak robotyzacja i sztuczna inteligencja. Współczesna gospodarka, zarówno w sektorze prywatnym, jak i państwowym coraz częściej opiera się o rozwiązania technologiczne, które umożliwiają automatyzację procesów, optymalizację pracy oraz podejmowanie decyzji w oparciu o analizę dużych zbiorów danych.

Robotyzacja odnosi się do procesu wdrażania robotów przemysłowych lub usługowych w miejsce lub jako uzupełnienie pracy ludzkiej, w celu zwiększenia efektywności, precyzji i powtarzalności działań. Roboty te mogą być programowalne i autonomiczne, a ich zastosowanie obejmuje m.in. produkcję, logistykę, opiekę zdrowotną czy usługi publiczne. Według Międzynarodowej Federacji Robotyki (ang. *International Federation of Robotics* – IFR), robotyzacja oznacza „projektowanie, konstruowanie i wykorzystywanie robotów w celu automatyzacji zadań, które tradycyjnie były wykonywane przez ludzi” (International Federation of Robotics, 2023).

Sztuczna inteligencja to dziedzina informatyki, której celem jest tworzenie systemów zdolnych do wykonywania zadań wymagających inteligencji ludzkiej, takich jak rozpoznawanie obrazów, analiza języka posiada wiele definicji. E. Rich określa ją jako „dziedzinę nauki zajmującą się tworzeniem programów komputerowych, które wykonują zadania wymagające inteligencji, gdy są wykonywane przez ludzi” (Rich, 1983, s. 119-120). W praktyce AI

przyjmuje różne formy – od prostych algorytmów opartych na regułach, przez uczenie maszynowe (ang. *machine learning*), aż po głębokie sieci neuronowe (ang. *deep learning*) zdolne do przetwarzania złożonych danych i podejmowania autonomicznych decyzji.

Robotyzacja i sztuczna inteligencja wzajemnie się przenikają. Coraz częściej roboty wyposaża się w komponenty AI, które pozwalają im nie tylko wykonywać powtarzalne zadania, lecz także uczyć się i adaptować do zmieniających się warunków. Tego rodzaju integracja technologii prowadzi do powstawania tzw. inteligentnych systemów robotycznych, wykorzystywanych zarówno w przemyśle (np. linie montażowe z robotami uczącymi się optymalizacji procesów), jak i w sektorze usługowym (np. roboty medyczne analizujące dane pacjentów).

Zarówno AI, jak i robotyka znalazły szerokie zastosowanie w wielu gałęziach gospodarki. W sektorze przemysłowym technologie te wykorzystywane są do automatyzacji produkcji, kontroli jakości, zarządzania magazynami czy planowania logistyki np. systemy oparte na AI umożliwiają predykcyjne utrzymanie ruchu (ang. *predictive maintenance*), co znacząco redukuje przestoje i koszty operacyjne. Inteligentne systemy decyzyjne łączą zdolności analityczne AI z regułami logiki biznesowej, wspierając menedżerów i instytucje w podejmowaniu trafniejszych i szybszych decyzji, szczególnie w zarządzaniu kryzysowym.

W sektorze usługowym AI znajduje zastosowanie w bankowości (np. analiza ryzyka kredytowego, wykrywanie oszustw), handlu (personalizacja ofert, zarządzanie zapasami), opiece zdrowotnej (diagnozowanie obrazowe, analiza danych pacjentów), w systemach rekomendacyjnych, prognozowaniu popytu. AI również jest stosowane w edukacji, w rolnictwie (precyzyjne opryski, zbiorczy), opiece nad osobami starszymi czy w administracji publicznej.

Korzyści z robotyzacji i AI

Wdrożenie technologii robotycznych i sztucznej inteligencji umożliwia automatyzację złożonych lub powtarzalnych procesów, zwiększenie precyzji operacji, redukcję kosztów oraz efektywniejsze zarządzanie informacją. Choć zakres i sposób wykorzystania tych technologii różni się w zależności od specyfiki sektora, podstawowe obszary korzyści pozostają wspólne (Tabela 1).

Tabela 1. Korzyści z wprowadzenia robotyzacji i AI w sektorze prywatnym i publicznym

W sektorze prywatnym	W sektorze publicznym (państwowym)
zwiększenie efektywności i obniżenie kosztów operacyjnych – robotyzacja i automatyzacja pozwalają na realizację procesów w trybie ciągłym (24/7), z minimalną ilością błędów i bez konieczności zatrzymywania pracy, co prowadzi do obniżenia kosztów produkcji oraz usług;	automatyzacja usług administracyjnych (e-administracja) – AI umożliwia zwiększenie dostępności i szybkości usług administracyjnych (załatwianie spraw urzędowych online), co zmniejsza koszty funkcjonowania urzędów i skraca czas obsługi interesantów, automatycznej weryfikacji wniosków czy rozliczeń podatkowych;
usprawnienie procesów produkcyjnych i logistycznych – dynamiczna optymalizacja linii montażowych, analiza czasu cyklu czy predykcyjne zarządzanie konserwacją (ang. <i>predictive maintenance</i>); zarządzanie łańcuchem dostaw, optymalizacja tras dostaw, prognozowanie zapotrzebowania bezpośrednio przekładają się na redukcję kosztów i poprawę terminowości dostaw;	lepsze zarządzanie danymi i zasobami publicznymi – AI wspomaga instytucje publiczne w analizie dużych zbiorów danych (ang. <i>big data</i>), co umożliwia lepsze planowanie zasobów i predykcję potrzeb społecznych;
poprawa jakości obsługi klienta (np. chatboty, analiza danych) – AI zmienia sposób interakcji z klientami – chatboty i wirtualni asystenci obsługują zapytania klientów w czasie rzeczywistym, poprawiając dostępność usług oraz odciążając personel; systemy analizy danych klientów (ang. <i>Customer Data Platforms</i>) umożliwiają personalizację ofert, lepsze targetowanie marketingowe oraz szybsze reagowanie na zmiany w zachowaniach konsumentów;	usprawnienie opieki zdrowotnej i edukacji – AI wspiera diagnozowanie chorób, analizę obrazów medycznych oraz personalizację leczenia, co może prowadzić do poprawy skuteczności terapii i ograniczenia kosztów; w edukacji technologie AI są wykorzystywane do tworzenia systemów nauczania adaptacyjnego, które dostosowują treści i tempo do indywidualnych potrzeb uczniów;
możliwość tworzenia innowacyjnych produktów i usług – nowych modeli biznesowych, produktów opartych na danych oraz usług cyfrowych np. inteligentne aplikacje finansowe, autonomiczne pojazdy, rozwiązania IoT (ang. <i>Internet of Things</i>) czy cyfrowi doradcy inwestycyjni (ang. <i>robo-advisors</i>).	zwiększenie przejrzystości i efektywności działania instytucji oraz ograniczenia korupcji – systemy zarządzania dokumentacją, cyfrowe rejestry i analiza danych pozwalają na lepszą kontrolę wydatków publicznych oraz zwiększenie zaufania obywateli do instytucji.

Źródło: opracowanie własne na podstawie: International Federation of Robotics, 2023; European Commission, 2023; Capgemini Research Institute, 2022; Topol, 2019.

Zagrożenia i wyzwania związane z robotyzacją i AI

Pomimo wymienionych wyżej korzyści wynikających z wdrażania robotyzacji i sztucznej inteligencji, technologie te niosą także szereg istotnych wyzwań i zagrożeń. Ich charakter i skala różnią się w zależności od sektora, lecz wspólnym mianownikiem pozostają konsekwencje społeczne, gospodarcze, technologiczne oraz etyczne. Brak odpowiednich regulacji oraz nadzoru nad rozwojem AI może prowadzić do pogłębienia nierówności, destabilizacji rynku pracy, a także naruszenia praw obywatelskich (Tabela 2).

Tabela 2. Zagrożenia i wyzwania związane z robotyzacją i AI w sektorze prywatnym i publicznym

W sektorze prywatnym	W sektorze publicznym (państwowym)
utrata miejsc pracy i zmiany na rynku pracy – występuje ryzyko zastępowania pracowników przez maszyny i algorytmy, zwłaszcza w zawodach o niskiej lub średniej kwalifikacji; przejście na gospodarkę opartą o AI wymaga przekwalifikowania znacznej części siły roboczej, co może być wyzwaniem zarówno dla firm, jak i państwa;	trudności w dostosowaniu przestarzałych struktur i procedur – polskie instytucje państwowe często działają w oparciu o biurokratyzowane, nieelastyczne schematy zarządzania, które utrudniają cyfryzację usług publicznych; brakuje też odpowiednich kompetencji cyfrowych wśród urzędników, co dodatkowo opóźnia proces modernizacji;
ryzyko uzależnienia od technologii i utrata kontroli nad procesami – silna zależność od zautomatyzowanych systemów niesie ryzyko ich niekontrolowanego działania, zwłaszcza w sytuacjach awaryjnych lub przy błędnych danych wejściowych – organizacje mogą stopniowo tracić kompetencje wewnętrzne w zakresie analizy i decyzyjności, oddając kontrolę algorytmom, których działań nie da się w pełni zrozumieć, a to budzi obawy o stabilność systemów krytycznych;	potencjalna marginalizacja grup społecznych (cyfrowe wykluczenie) – automatyzacja i cyfryzacja usług publicznych mogą prowadzić do wykluczenia osób nieposiadających odpowiednich umiejętności cyfrowych lub dostępu do technologii; zjawisko to dotyka w szczególności osoby starsze, osoby z niepełnosprawnościami oraz mieszkańców obszarów wiejskich;
kwestie etyczne i odpowiedzialność za decyzje podejmowane przez AI – brak jasnych ram prawnych dotyczących odpowiedzialności za działania systemów AI stwarza istotne problemy prawne i etyczne, ponieważ niejasne jest kto ponosi odpowiedzialność za błędną decyzję systemu kredytowego lub medycznego – projektant, użytkownik, a może producent?	ryzyko nadużyć w nadzorze i zbieraniu danych obywateli – wykorzystanie AI do nadzoru (np. systemy rozpoznawania twarzy, analiza zachowań online) budzi poważne wątpliwości etyczne i prawne; brak przejrzystości w działaniu takich systemów może prowadzić do nadużyć w zakresie inwigilacji obywateli i naruszenia ich praw podstawowych;

W sektorze prywatnym	W sektorze publicznym (państwowym)
bezpieczeństwo danych i prywatność – systemy oparte na AI działają w oparciu o duże ilości danych, w tym często danych osobowych – wyciek, niewłaściwe przetwarzanie lub profilowanie użytkowników może naruszać ich prywatność i prowadzić do nadużyć; problematyczne jest także stosowanie tzw. algorytmicznych technik manipulujących decyzjami użytkowników.	wysokie koszty wdrożeń i ryzyko porażek projektów – wdrożenie zaawansowanych systemów opartych na AI wymaga znacznych nakładów finansowych, a także precyzyjnego planowania i koordynacji; brak odpowiedniego zarządzania projektami technologicznymi może prowadzić do ich opóźnień, przekroczenia budżetów lub całkowitego niepowodzenia.

Źródło: opracowanie własne na podstawie: Frey i Osborne, 2013; Brynjolfsson i McAfee, 2014; Dignum, 2019; Burrell, 2016; Mittelstadt i in., 2016; EDRi, 2020; Zuboff, 2019; Mathur i in., 2019.

Przykłady wdrożeń AI i robotyzacji

Wdrażanie technologii sztucznej inteligencji i robotyzacji w różnych sektorach gospodarki ma wymierny wpływ na efektywność, jakość usług i konkurencyjność organizacji. Poniżej przedstawiono wybrane studia przypadków z sektora prywatnego i publicznego, ukazujące zarówno sukcesy, jak i trudności związane z implementacją nowoczesnych technologii.

Sektor prywatny

1. Przemysł: AI i robotyzacja w Grupie Volkswagen Poznań.

W ramach procesu transformacji cyfrowej firma zainwestowała w zautomatyzowane linie montażowe oraz inteligentne systemy kontroli jakości oparte na wizji maszynowej. Roboty współpracujące (tzw. *cobots*) wykonują precyzyjne czynności w montażu silników, a dane produkcyjne są analizowane w czasie rzeczywistym w celu optymalizacji procesów. W efekcie odnotowano wzrost wydajności oraz zmniejszenie liczby błędów produkcyjnych, jednocześnie firma prowadzi programy przekwalifikowania pracowników do pracy w nowych technologiach.

2. Handel: personalizacja ofert i *chatboty* w e-commerce.

Polskie sklepy internetowe, takie jak *Empik.com* czy *Allegro*, wdrażają AI w zakresie analizy zachowań klientów i personalizacji oferty. Na

podstawie algorytmów uczenia maszynowego rekomendowane są produkty, przewidywane preferencje zakupowe i optymalizowane kampanie marketingowe. *Chatboty* obsługujące klientów w trybie 24/7 poprawiają dostępność usług i odciążają zespoły *call center*.

3. Bankowość: AI w obsłudze klienta i ocenie ryzyka kredytowego.
Banki komercyjne w Polsce, m.in. ING Bank Śląski i PKO Bank Polski, wdrażają AI w systemach *scoringu* kredytowego, analizie transakcji pod kątem oszustw oraz w *chatbotach* bankowości mobilnej. Przykładem jest asystent głosowy „IKO”, który umożliwia klientom obsługę konta za pomocą komend głosowych. AI przyspiesza proces decyzyjny, zmniejsza koszty operacyjne i poprawia doświadczenia klientów.

Sektor publiczny

1. Cyfrowa administracja: e-Urząd Skarbowy.
W Polsce istotnym elementem transformacji cyfrowej administracji jest rozwój e-Urzędu Skarbowego, który umożliwia m.in. automatyczne rozliczanie deklaracji PIT oraz komunikację z urzędnikami *online*. Platforma bazuje na integracji baz danych oraz wykorzystaniu automatycznych systemów klasyfikacji dokumentów i ich weryfikacji (Ministerstwo Finansów, 2023).
2. Opieka zdrowia: AI w diagnostyce medycznej (projekt AIDMED).
Projekt AIDMED, rozwijany przez polski start-up we współpracy z ośrodkami medycznymi, wykorzystuje AI do zdalnego monitorowania stanu zdrowia pacjentów z chorobami przewlekłymi. Urządzenia analizują dane EKG, saturację oraz parametry oddechowe, a algorytmy klasyfikują pacjentów wymagających interwencji (AIDMED, 2021). Zastosowanie tego rozwiązania zmniejsza obciążenie personelu medycznego i poprawia jakość opieki. System był testowany m.in. w placówkach publicznych podczas pandemii COVID-19.

Wdrażanie AI i robotyzacji w sektorze zarówno prywatnym, jak i państwowym przynosi liczne korzyści – zwiększenie efektywności, zmniejszenie kosztów, poprawę jakości usług – ale wiąże się też z wyzwaniami.

Analizując dostępne dane, można zauważyć, że sukcesy wdrożeń robotyzacji i AI dotyczą głównie firm i instytucji, które:

- odpowiednio przygotowały proces zmiany (transformacja kompetencyjna),
- posiadały dane dobrej jakości,
- oraz miały jasno określony cel technologiczny i biznesowy.

Porażki często wynikają z:

- nieadekwatnej analizy potrzeb użytkowników,
- złego dopasowania technologii do infrastruktury,
- niedostatecznego przeszkolenia kadr,
- lub zbyt ambitnych celów przy ograniczonych zasobach.

Cyberbezpieczeństwo a robotyzacja i AI

Wraz z dynamicznym rozwojem robotyzacji i sztucznej inteligencji rośnie znaczenie kwestii bezpieczeństwa. Systemy oparte na AI oraz roboty autonomiczne coraz częściej integrują się z infrastrukturą krytyczną, sieciami produkcyjnymi oraz usługami publicznymi, co stawia nowe wyzwania dla cyberbezpieczeństwa, zarówno na poziomie technicznym, jak i organizacyjnym.

Wyzwania dla cyberbezpieczeństwa infrastruktury technicznej oraz systemowej są następujące:

1. złożoność systemów i podatność na ataki,
2. bezpieczeństwo danych i prywatność,
3. wyzwania organizacyjne i prawne,
4. braki kadrowe i edukacyjne.

Systemy AI i roboty autonomiczne cechuje wysoka złożoność, często działają w oparciu o sieci neuronowe o nieprzejrzyistych mechanizmach („czarna skrzynka”). To utrudnia wykrywanie i neutralizację nowych typów ataków, takich jak ataki *adversarialne*, gdzie celowo modyfikuje się dane wejściowe, by wprowadzić system w błąd. Bezpieczeństwo państwa oraz przemysłu wymaga nie tylko ochrony tradycyjnych systemów informatycznych, ale również implementacji kompleksowych strategii cyberobrony, które uwzględniają specyfikę AI i robotyzacji (Janczewski, 2022, s. 139-158). Szczególne zagrożenie stanowią ataki na systemy kontrolujące infrastrukturę krytyczną, gdzie skutki

incydentów mogą mieć wymiar narodowy. Ponadto skuteczne zarządzanie cyberbezpieczeństwem wymaga podejścia systemowego, łączącego technologie zabezpieczeń, audyt procesów oraz ciągle podnoszenie świadomości pracowników w firmach i instytucjach (Kosiński, 2015, s. 71).

Systemy AI i roboty przetwarzają ogromne ilości danych, często wrażliwych, np. medycznych czy finansowych. Ich zabezpieczenie jest kluczowe, by zapobiec wyciekom i nadużyciom, zgodnie z przepisami RODO oraz krajowymi regulacjami. Polska Grupa ds. Cyberbezpieczeństwa podkreśla, że transparentność algorytmiczna i kontrola dostępu są fundamentem zaufania do tych technologii (Ministerstwo Cyfryzacji, 2023).

Na rynku istnieje potrzeba stworzenia jasnych ram regulacyjnych i prawnych dotyczących odpowiedzialności za działania autonomicznych systemów AI. Brak precyzyjnych norm komplikuje reagowanie na cyberzagrożenia i ustalanie odpowiedzialności za szkody.

Polski rynek cyberbezpieczeństwa cierpi także na deficyt wykwalifikowanych specjalistów. Od pracowników wymaga się umiejętności komunikowania się z maszyną – rozumienia specyficznego języka, który może pozwolić na znalezienie ważnych informacji dla firmy lub rynku oraz odczytania, przetwarzania otrzymanych informacji i zinterpretowania zaleceń czy działań wygenerowanych przez system (Szymańska, Janczewski, 2023, s. 30).

Przyszłość robotyzacji i AI – prognozy i rekomendacje

Rozwój robotyzacji i sztucznej inteligencji będzie nadal dynamiczny, napędzany rosnącymi możliwościami obliczeniowymi, coraz lepszym dostępem do danych oraz postępem w algorytmach uczenia maszynowego. Przewiduje się, że technologie AI będą coraz częściej integrowane z systemami autonomicznymi, robotami współpracującymi (*cobotami*), a także rozwiązaniami opartymi na *edge computing* i *Internet of Things* (IoT).

W Polsce strategicznym kierunkiem jest rozwój inteligentnych systemów wspierających Przemysł 4.0, które poprawiają efektywność produkcji oraz zarządzanie łańcuchem dostaw. Ponadto zwraca się uwagę na rosnące znaczenie technologii AI w sektorze publicznym, zwłaszcza w kontekście cyfryzacji usług administracyjnych i e-zdrowia.

Przedsiębiorstwa i instytucje publiczne powinny inwestować w rozwój kompetencji cyfrowych swoich pracowników (Janczewski, Szymańska, 2024, s. 191) a także wdrażać rozwiązania AI w sposób odpowiedzialny i przemyślany. Konieczne jest prowadzenie audytów ryzyka oraz testowanie systemów pod kątem bezpieczeństwa i transparentności ich działania. Równolegle z wdrożeniami powinny pojawić się odpowiednie regulacje prawne. Konieczne jest ustanowienie jasnych norm dotyczących odpowiedzialności za decyzje podejmowane przez autonomiczne systemy, a także zapewnienie ochrony prawnej osób potencjalnie poszkodowanych przez błędy lub awarie tych systemów.

Ważnym aspektem jest również współpraca międzysektorowa oraz wymiana doświadczeń – tworzenie platform kooperacji między sektorem prywatnym, publicznym i środowiskiem akademickim, co sprzyja innowacyjności i przyspiesza adaptację nowych technologii.

Podsumowanie

Podsumowując, automatyzacja, robotyzacja, sztuczna (pozorna) inteligencja stają się nieodzownym elementem każdej działalności biznesowej. Technologie cyfrowe pozwalają przyspieszać obieg i wymianę informacji, gromadzić dane, które stanowią podstawy decyzyjne dla menedżerów. W wyniku cyfrowej transformacji zmieniają się procesy produkcji i konsumpcji, charakter pracy, formy zatrudnienia i modele biznesowe. Wiele obszarów funkcjonalnych w przedsiębiorstwach, dzięki systemom informatycznym zostało zautomatyzowanych, uproszczonych, jak i uporządkowanych w logiczne procesy, eliminujące zbędne, powtarzalne czynności, jednak równocześnie wywołują poważne wyzwania – społeczne, etyczne, prawne oraz związane z bezpieczeństwem.

Postęp robotyzacji i automatyzacji na rynku pracy pokazuje wzrost zapotrzebowania na pracowników z kompetencjami cyfrowymi, które są wyznacznikiem pozycji zawodowej w zdigitalizowanym świecie. Ponadto rozwój systemów autonomicznych i inteligentnych niesie ze sobą potrzebę nowego podejścia do ochrony infrastruktury, danych i ciągłości działania. Zintegrowane systemy robotyczne i AI, działające w środowiskach przemysłowych, medycznych czy administracyjnych, muszą być projektowane z uwzględnieniem potencjalnych zagrożeń cybernetycznych już na etapie planowania.

Wyzwaniami związanymi z analizowaniem i monitorowaniem efektów transformacji cyfrowej, rozwoju gospodarki i przedsiębiorstw są opracowanie wskaźników mierzących wpływ na rozwój gospodarczy państwa i przedsiębiorstw oraz bezpieczeństwo, które wymaga podejścia systemowego do zarządzania danymi, procesami przepływu informacji, infrastrukturą i zarządzania umiejętnościami pracowników.

W dobie automatyzacji i cyfryzacji tylko holistyczne podejście – łączące technologię, prawo, etykę i cyberbezpieczeństwo – pozwoli w pełni wykorzystać potencjał robotyzacji i AI.

Literatura

1. AIDMED Sp. z o.o. (2021). *Projekt badawczy: ABM „System wspomagający zdalną diagnostykę pacjentów leczonych w warunkach domowych, umożliwiający wykrywanie nagłego zaostrzenia się objawów COVID-19 na bazie metod sztucznej inteligencji”*. Pobrane z: <https://www.aidmed.ai/pl/abm/> (dostęp: 12.03.2025).
2. Bostrom, N. (2014). *Superintelligence: Paths, Dangers, Strategies*. Oxford University Press.
3. Brynjolfsson, E., McAfee, A. (2014). *The Second Machine Age*. W. W. Norton & Company.
4. Burrell, J. (2016). How the Machine ‘Thinks’: Understanding Opacity in Machine Learning Algorithms. *Big Data & Society*, 3(1). <https://doi.org/10.1177/2053951715622512>
5. Capgemini Research Institute. (2022). *Intelligent Supply Chain*. Pobrane z: <https://www.capgemini.com/wp-content/uploads/2022/12/Report-Intelligent-Supply-Chain.pdf> (dostęp: 12.03.2025).
6. Dignum, V. (2019). *Responsible Artificial Intelligence*. Springer. <https://doi.org/10.1007/978-3-030-30371-6>
7. EDRi. (2020). *Ban Biometric Mass Surveillance*. Pobrane z: <https://edri.org/wp-content/uploads/2020/05/Paper-Ban-Biometric-Mass-Surveillance.pdf> (dostęp: 12.03.2025).
8. European Commission. (2023). *eGovernment benchmark 2023*. Publications Office of the European Union.
9. Frey, C. B., Osborne, M. A. (2013). *The Future of Employment: How Susceptible Are Jobs to Computerisation?* Oxford Martin School.

10. International Federation of Robotics. (2023). *World Robotics Report*. IFR.
11. Janczewski, R. (2022). *Cyberbezpieczeństwo w życiu społecznym*. W: J. Stala, M. Butrymowicz (red.), *W służbie społeczeństwu. Polska w obronie praw człowieka na świecie i w kraju* (s. 139-158). Wydawnictwo Naukowe Uniwersytetu Papieskiego Jana Pawła II. <https://doi.org/10.15633/9788374389891.09>
12. Janczewski, R., Szymańska K. (2024). *Economic Determinants of the Economy and Enterprise in the Conditions of Digital Transformation*. International Scientific and Practical Conference „Human Resource Management”. University of Economics – Varna.
13. Kosiński, J. (2015). *Paradygmaty cyberprzestępczości*. Difin.
14. Mathur, A., Acar, G., Friedman, M. J., Mayer, J., Chetty, M., Narayanan, A. (2019). Dark Patterns at Scale: Findings from a Crawl of 11K Shopping Websites. *Proceedings of the ACM on Human-Computer Interaction*, 3(CSCW), Article 81. <https://doi.org/10.1145/3359183>
15. Ministerstwo Cyfryzacji. (2023). *Sprawozdanie Pełnomocnika Rządu do Spraw Cyberbezpieczeństwa za 2023 rok*. Pobrane z: <https://www.gov.pl/web/cyfryzacja/krajobraz-cyberprzestrzeni> (dostęp: 12.03.2025).
16. Ministerstwo Finansów. (2023). *e-Urząd Skarbowy*. Pobrane z: <https://www.gov.pl/web/finanse/e-urzed-skarbowy> (dostęp: 12.03.2025).
17. Mittelstadt B. D., Allo, P., Taddeo, M., Wachter, S., Floridi, L. (2016). The Ethics of Algorithms: Mapping the Debate. *Big Data & Society*, <https://doi.org/10.1177/2053951716679679>
18. Rich, E. (1983). *Artificial Intelligence*. McGraw-Hill.
19. Schwab, K. (2016). *The Fourth Industrial Revolution*. World Economic Forum.
20. Szymańska, K., Janczewski, R. (2023). Ekonomiczne uwarunkowania cyfryzacji i robotyzacji w gospodarce i przedsiębiorstwie. W: K. Szymańska, R. A. Janczewski (red.), *Problemy i wyzwania ekonomii i zarządzania w XXI wieku. Wybrane aspekty* (s. 31-45). Grupa Wydawnicza FNCE.
21. Topol, E. (2019). *Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again*. Basic Books.
22. Zuboff, S. (2019). *The Age of Surveillance Capitalism*. Public Affairs.

mgr inż. Władysław Blocki¹

Wyższa Szkoła Informatyki i Zarządzania w Rzeszowie

ALGORYTMY GRAFOWE W ERZE SZTUCZNEJ INTELIGENCJI: INTELIGENTNE ROZWIĄZANIA DLA INFORMATYKI

GRAPH ALGORITHMS IN THE ERA OF ARTIFICIAL INTELLIGENCE: INTELLIGENT SOLUTIONS FOR COMPUTER SCIENCE

Streszczenie

Celem niniejszego rozdziału jest przedstawienie współczesnego znaczenia algorytmów grafowych w kontekście rozwoju sztucznej inteligencji, rozumianej jako dominacja metod uczenia maszynowego i głębokiego opartych na uczeniu reprezentacji (w tym modeli operujących bezpośrednio na strukturach grafowych). Analiza obejmuje zarówno podstawy teoretyczne, jak i nowoczesne techniki uczenia reprezentacji, ze szczególnym uwzględnieniem sieci neuronowych operujących na strukturach grafowych. Wskazano na ograniczenia klasycznych metod analizy grafów, które pomimo swojej fundamentalnej roli okazują się niewystarczające w obliczu współczesnych wymagań wynikających z przetwarzania danych o ogromnej skali i wysokim stopniu złożoności relacyjnej. W dalszej części omówiono zagadnienie skalowalności i złożoności obliczeniowej systemów grafowych, ze szczególnym uwzględnieniem przetwarzania rozproszonego oraz technik redukcji grafów. Przedstawiono również wybrane zastosowania algorytmów grafowych w takich obszarach, jak telekomunikacja, bioinformatyka, analityka sieci wiedzy czy cyberbezpieczeństwo. Ostatnia część poświęcona jest

¹ <https://orcid.org/0009-0000-0006-9479>, e-mail: w.blocki@doktorat.wsiz.edu.pl
Blocki, W. (2026). Algorytmy grafowe w erze sztucznej inteligencji: inteligentne rozwiązania dla informatyki. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 21-43). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_2

analizie kierunków dalszego rozwoju, zwłaszcza metod neurosymbolicznych i rozwiązań inspirowanych obliczeniami kwantowymi.

Słowa kluczowe: algorytmy grafowe, sztuczna inteligencja, sieci neuronowe na grafach, uczenie reprezentacji grafowych, grafy wiedzy, skalowalność obliczeń, AI neurosymboliczna, algorytmy kwantowe

Abstract

The aim of this chapter is to present the contemporary role of graph algorithms in the context of the development of artificial intelligence, particularly machine learning and deep learning methods based on representation learning, including models that operate directly on graph structures. The analysis covers both theoretical foundations and modern representation learning techniques, with particular emphasis on Graph Neural Networks (GNNs). The paper highlights the limitations of classical graph analysis methods, which, despite their fundamental importance, prove insufficient in the face of modern requirements arising from the processing of large-scale data and high relational complexity. Issues of scalability and computational complexity in graph-based systems are discussed, with particular attention to distributed processing and graph reduction techniques. Selected applications of graph algorithms are presented in areas such as telecommunications, bioinformatics, knowledge graph analytics, and cybersecurity. The final section discusses future research directions, particularly neuro-symbolic approaches and solutions inspired by quantum computing.

Keywords: graph algorithms, artificial intelligence, graph neural networks, representation learning, knowledge graphs, computational scalability, neuro-symbolic AI, quantum computing algorithms

Wstęp

Współczesne badania nad algorytmami grafowymi opierają się na dwóch filarach. Pierwszym jest historyczne znaczenie grafów jako narzędzia do opisu relacji. Drugim jest technologiczna transformacja wymuszona przez rozwój sztucznej inteligencji (AI). Pierwotnie grafy rozwijano w matematyce dyskretnej jako abstrakcyjne struktury formalne. Obecnie stały się kluczowym modelem reprezentacji informacji w systemach obliczeniowych (Diestel, 2018, s. 1). Zmiana ta wynika z przesunięcia paradygmatu analitycznego, a nie tylko z rosnącej skali danych. Współczesne systemy informatyczne operują coraz częściej na danych, których najistotniejszą właściwością jest relacyjność. Dane

przestają być zbiorem izolowanych rekordów – stają się elementami sieci zależności, których struktura ma znaczenie równie istotne jak wartości atrybutów. Wzrost znaczenia grafów w sztucznej inteligencji wynika z kilku nakładających się procesów. Po pierwsze, wykładniczo rosnąca ilość danych generowanych przez systemy cyfrowe doprowadziła do sytuacji, w której ich interpretacja wymaga rekonstrukcji powiązań między obiektami (Leskovec i in., 2020). Graf stał się naturalną formą reprezentacji tej złożoności – umożliwiającą zarówno przechowywanie, jak i analizę danych o strukturze sieciowej.

Po drugie, rozwój metod uczenia maszynowego – szczególnie uczenia głębokiego – stworzył zapotrzebowanie na modele zdolne do przetwarzania danych o strukturze nieliniowej. Klasyczne reprezentacje tabelaryczne okazują się niewystarczające w sytuacjach, gdy kluczowe znaczenie mają zależności topologiczne. W tej perspektywie graf nie jest jedną z wielu form reprezentacji, lecz rozszerzeniem przestrzeni modelowania, umożliwiającym opis danych, których nie da się adekwatnie przedstawić w strukturach liniowych (Newman, 2018).

Po trzecie, rosnąca interdyscyplinarność badań sprawia, że grafy stają się wspólnym językiem opisu zjawisk w informatyce, biologii, ekonomii, socjologii czy humanistyce cyfrowej. Modele epidemiologiczne, sieci transportowe, systemy finansowe, struktury molekularne, zależności semantyczne w języku naturalnym czy grafy wiedzy łączy potrzeba formalnego ujęcia relacji. Dzięki swojej elastyczności teoretycznej i bogactwu narzędzi analitycznych graf pozostaje jednym z niewielu modeli zdolnych sprostać tej różnorodności (Barabási, 2016).

Równocześnie z rosnącą popularnością grafów pojawiają się nowe wyzwania. Analiza struktur obejmujących miliony lub miliardy wierzchołków wymaga nie tylko optymalizacji algorytmicznej, lecz także nowych paradygmatów obliczeniowych. Problemy skalowalności, efektywności równoległej czy złożoności obliczeniowej pozostają kluczowe (Cormen i in., 2022). Jednocześnie współczesne modele grafowe muszą odpowiadać na pytania dotyczące ekspresywności, stabilności reprezentacji oraz interpretowalności wyników.

Celem niniejszego rozdziału jest syntetyczna analiza ewolucji algorytmów grafowych w trzech wymiarach: klasycznych metod deterministycznych, metod uczenia reprezentacji grafowych (w szczególności sieci neuronowych grafowych) oraz integracji grafów z podejściami neurosymbolicznymi

i obliczeniami kwantowymi. Tezą rozdziału jest stwierdzenie, że graf przekształcił się z narzędzia analizy strukturalnej w centralny model integrujący różne paradygmaty współczesnej sztucznej inteligencji. W kolejnych częściach omówione zostaną podstawy teoretyczne konstrukcji grafów, ich klasyczne zastosowania algorytmiczne oraz współczesne rozszerzenia związane z uczeniem maszynowym i modelowaniem relacyjnym. Rozdział zamyka syntetyczne podsumowanie wskazujące kierunki dalszego rozwoju metod grafowych w kontekście skalowalności, integracji paradygmatów oraz rosnącej złożoności systemów informatycznych.

W opracowaniu dokonano przeglądu literatury z lat 1956-2024, selekcjonując prace na podstawie ich wpływu na rozwój dziedziny (liczby cytowań) oraz innowacyjności w obszarze sieci neuronowych na grafach (GNN) i AI neurosymbolicznej. Taka perspektywa pozwala wskazać kierunek ewolucji od metod deterministycznych ku systemom uczącym się struktur relacyjnych.

W niniejszym rozdziale określenie „w erze sztucznej inteligencji” nie oznacza ogólnej historii AI, lecz etap rozwoju metod *data-driven*, w którym kluczową rolę odgrywają uczenie reprezentacji, uczenie głębokie oraz modele zdolne do przetwarzania danych relacyjnych. W tym ujęciu graf pełni podwójną funkcję: pozostaje formalnym obiektem analizowanym klasycznymi algorytmami deterministycznymi oraz staje się nośnikiem struktury danych w systemach uczących się (embeddingi, GNN, grafy wiedzy), gdzie relacje są istotne równie mocno jak same atrybuty.

Zakres rozdziału obejmuje: podstawy teorii grafów i wybrane klasyczne algorytmy jako fundament, metody uczenia reprezentacji grafowych oraz sieci neuronowe grafowe, zagadnienia skalowalności (w tym przetwarzanie rozproszone i redukcję grafów), przykładowe obszary zastosowań oraz kierunki rozwoju na styku grafów z neurosymboliką i podejściami inspirowanymi obliczeniami kwantowymi. Wątki neurosymboliczne i kwantowe mają charakter przeglądowy (perspektywy i scenariusze zastosowań), bez wchodzenia w pełną formalną teorię i szczegółowe implementacje.

Podstawy teorii grafów

Teoria grafów stanowi jedno z najbardziej wszechstronnych narzędzi matematyki dyskretnej, umożliwiających opis i analizę struktur relacyjnych

o złożonej topologii. Jej znaczenie wykracza daleko poza klasyczny kontekst matematyczny – współcześnie grafy funkcjonują jako podstawowy model reprezentacji w informatyce, bioinformatyce, analizie sieci społecznych, ekonomii czy lingwistyce obliczeniowej. W najbardziej ogólnym ujęciu graf definiuje się jako uporządkowaną parę $G = (V, E)$, gdzie V oznacza zbiór wierzchołków, a E zbiór krawędzi, czyli relacji pomiędzy elementami zbioru V (Newman, 2018, s. 3). Konstrukcja ta, mimo swojej formalnej prostoty, umożliwia modelowanie relacji symetrycznych i asymetrycznych, statycznych i dynamicznych, deterministycznych oraz probabilistycznych.

Współczesne zastosowania wymagają jednak rozszerzenia klasycznej definicji grafu o elementy zwiększające jego ekspresywność. W praktyce analizuje się grafy ważne, w których każdej krawędzi przypisuje się wartość numeryczną reprezentującą koszt, siłę lub prawdopodobieństwo relacji, grafy atrybutowane, gdzie wierzchołki i krawędzie posiadają zestawy cech semantycznych, grafy skierowane, umożliwiające modelowanie zależności przyczynowych, a także grafy heterogeniczne obejmujące wiele typów wierzchołków i relacji. Rozszerzenia te doprowadziły do powstania złożonych struktur, takich jak grafy wielowarstwowe, grafy molekularne czy grafy wiedzy, które odgrywają kluczową rolę w analizie danych wielkoskalowych (Leskovec i in., 2020).

Istotnym aspektem teorii grafów jest jej aparatura strukturalna, umożliwiająca systematyczną analizę własności topologicznych. Do podstawowych pojęć należą stopień wierzchołka, ścieżka, cykl, spójność, odległość oraz centralność. Każde z nich opisuje odmienny wymiar relacyjnej natury danych: centralność pozwala mierzyć znaczenie elementu w strukturze grafu, odległość określa efektywność komunikacji, natomiast spójność wskazuje odporność sieci na zakłócenia. Formalizacja tych pojęć umożliwiła rozwój klasycznych algorytmów analizy grafów, obejmujących wyznaczanie najkrótszych ścieżek, minimalnych drzew rozpinających oraz przepływów sieciowych (Cormen i in., 2022). Algorytmy te stanowią fundament współczesnych metod przetwarzania danych relacyjnych. Szczególne znaczenie ma ujęcie macierzowe i spektralne grafów, które pozwala przejść od struktur dyskretnych do reprezentacji algebraicznych. Macierz sąsiedztwa oraz macierz Laplasjanu stanowią podstawę analizy spektralnej, umożliwiając badanie stabilności, procesów dyfuzji oraz własności klasteryzacyjnych przy użyciu narzędzi algebry liniowej (Chung, 1997). Ujęcie to stało się jednym z fundamentów nowoczesnych metod

obliczeniowych w uczeniu maszynowym, w szczególności grafowych operacji konwolucyjnych.

Podsumowując, teoria grafów nie stanowi jedynie formalnego punktu wyjścia dla analizy struktur relacyjnych. Jest ona równocześnie podstawą metod wykorzystywanych we współczesnych systemach obliczeniowych, w których kluczowe znaczenie ma modelowanie złożonych, nieliniowych zależności między obiektami.

Klasyczne algorytmy grafowe i ich ograniczenia

Klasyczne algorytmy grafowe stanowią fundament rozwoju współczesnej informatyki, dostarczając podstawowych mechanizmów analizy i przetwarzania struktur relacyjnych. Choć wiele z nich powstało w drugiej połowie XX wieku, ich koncepcje pozostają aktualne, a część z nich stała się punktem wyjścia dla późniejszych metod wykorzystywanych w uczeniu maszynowym, analizie sieci oraz grafowych przekształceniach liniowych. W niniejszym rozdziale przedstawiono syntetyczną charakterystykę najważniejszych klas klasycznych algorytmów grafowych oraz ich znaczenie dla współczesnych zastosowań. Tradycyjnie w centrum analiz grafowych znajdują się algorytmy przeszukiwania grafu, przede wszystkim przeszukiwanie w głąb (ang. *depth-first search* – DFS) oraz przeszukiwanie wszerz (ang. *breadth-first search* – BFS). Oba należą do najbardziej elementarnych procedur operujących na grafach i stanowią podstawę wielu bardziej zaawansowanych metod, takich jak wykrywanie cykli, sortowanie topologiczne, wyznaczanie komponentów spójności czy analiza własności strukturalnych grafów skierowanych (Cormen i in., 2022). Ich istotną cechą jest deterministyczny charakter oraz liniowa złożoność względem liczby wierzchołków i krawędzi, co czyni je wyjątkowo efektywnymi w grafach średniej skali. W sensie koncepcyjnym BFS i DFS stworzyły ramy obliczeniowe, które stały się podstawą dalszego rozwoju metod grafowych.

Drugą fundamentalną kategorię stanowią algorytmy wyznaczania najkrótszych ścieżek. Najbardziej klasycznym z nich jest algorytm Dijkstry, umożliwiający wyznaczenie optymalnych ścieżek w grafach o nieujemnych wagach. Jego konstrukcja opiera się na iteracyjnej relaksacji odległości i sukcesywnym rozszerzaniu zbioru wierzchołków o ustalonej minimalnej odległości (Dijkstra, 1959, s. 269). Algorytm ten stał się podstawą współczesnych systemów

routingu, optymalizacji komunikacji oraz analiz przestrzennych. W sytuacjach, w których dopuszczalne są wagi ujemne, stosuje się algorytm Bellmana-Forda, który charakteryzuje się większą złożonością obliczeniową, lecz gwarantuje poprawność w szerszej klasie problemów (Bellman, 1958, s. 87). Równie istotną rolę odgrywają algorytmy minimalnego drzewa rozpinającego (ang. *minimum spanning tree* – MST). Algorytmy Kruskala oraz Prima umożliwiają wyznaczenie podzbioru krawędzi minimalizującego sumaryczny koszt połączeń przy zachowaniu spójności grafu (Kruskal, 1956). Metody te znalazły zastosowanie w projektowaniu infrastruktury, kompresji danych, klasteryzacji oraz analizie sieci fizycznych i logicznych. Ich znaczenie wykracza poza zastosowania praktyczne – koncepcja zachłannej optymalizacji grafowej stała się inspiracją dla wielu późniejszych metod heurystycznych. Odrębną klasę stanowią algorytmy przepływu w sieciach, takie jak metoda Forda-Fulkersona oraz jej wariant Edmonds-Karp. Celem tych algorytmów jest wyznaczenie maksymalnego przepływu pomiędzy dwoma wyróżnionymi wierzchołkami grafu przy uwzględnieniu ograniczeń przepustowości krawędzi (Ford, Fulkerson, 1962). Metody przepływowe znalazły zastosowanie w logistyce, analizie sieci transportowych, przydziale zasobów oraz w problemach wyznaczania minimalnego przekroju. Choć ich złożoność przewyższa złożoność algorytmów przeszukiwania czy MST, ich znaczenie praktyczne jest fundamentalne, ponieważ modelują procesy przepływu energii, informacji i zasobów w systemach rzeczywistych. Klasyczne algorytmy grafowe wykazują jednak ograniczenia, które ujawniają się w kontekście współczesnych, wielkoskalowych i dynamicznych sieci. Większość z nich zakłada pełną dostępność struktury grafu w pamięci operacyjnej, co staje się problematyczne w przypadku struktur obejmujących miliardy wierzchołków. Ponadto projektowane były z myślą o grafach statycznych, podczas gdy współczesne sieci – społeczne, informacyjne czy biologiczne – cechują się dynamiczną zmiennością relacji w czasie (Leskovec i in., 2020). Dodatkowo metody te nie operują bezpośrednio na danych atrybutowych, co ogranicza ich zastosowanie w analizach wymagających integracji informacji semantycznych.

Mimo tych ograniczeń klasyczne algorytmy grafowe pozostają niezbędnym punktem odniesienia dla współczesnych metod obliczeniowych. Stanowią one teoretyczne zaplecze dla wielu nowoczesnych algorytmów grafowych, zarówno deterministycznych, jak i probabilistycznych, a także dostarczają

formalnego języka opisu problemów grafowych, umożliwiającego porównywanie efektywności metod klasycznych i współczesnych.

Integracja algorytmów grafowych z uczeniem maszynowym

Integracja algorytmów grafowych z metodami uczenia maszynowego stała się jednym z kluczowych kierunków rozwoju współczesnej sztucznej inteligencji. Wzrost znaczenia danych relacyjnych, obejmujących zarówno struktury społeczne, molekularne, jak i językowe, ujawnił ograniczenia klasycznych modeli, które nie były zdolne do uchwycenia zależności topologicznych pomiędzy obiektami (Bronstein i in., 2017). Wprowadzenie uczenia grafowego umożliwiło przetwarzanie informacji w sposób zgodny z relacyjną naturą danych, w których semantyka wynika nie tylko z cech jednostkowych, lecz z konfiguracji powiązań między elementami struktury.

Centralnym mechanizmem współczesnych metod uczenia na grafach jest koncepcja propagacji wiadomości (*message passing*), rozumiana jako iteracyjny proces aktualizacji reprezentacji wierzchołków na podstawie informacji agregowanych od ich sąsiadów. Formalizacja tego podejścia w postaci *Message Passing Neural Networks* (MPNN) pozwoliła na systematyczne połączenie narzędzi analizy grafowej z elastycznością modeli głębokiego uczenia (Gilmer i in., 2017, s. 1274). Kluczową własnością tych modeli jest niezmienniczość względem permutacji sąsiedztwa, zapewniająca poprawność semantyczną operacji agregacji.

Rozwój metod konwolucyjnych na grafach znacząco poszerzył zakres zastosowań uczenia grafowego. *Graph Convolutional Networks* (GCN), zaproponowane przez Kipfa i Wellinga, uogólniły operację splotu na struktury nieregularne poprzez wykorzystanie znormalizowanej macierzy sąsiedztwa i transformacji liniowych (Kipf, Welling, 2017, s. 3). Umożliwiło to efektywne łączenie informacji o cechach wierzchołków z lokalną strukturą grafu. Jednocześnie wykazano, że wraz ze wzrostem liczby warstw GCN dochodzi do zjawiska nadmiernego wygładzania reprezentacji (*oversmoothing*), prowadzącego do utraty zdolności rozróżniania odległych wierzchołków.

W odpowiedzi na te ograniczenia rozwinięto modele uwagowe, takie jak *Graph Attention Networks* (GAT), w których zastosowanie mechanizmu uwagi pozwala dynamicznie różnicować wpływ poszczególnych sąsiadów (Veličković

i in., 2018, s. 5). Mechanizm ten zwiększa elastyczność reprezentacyjną modelu, umożliwiając kontekstową interpretację relacji. Modele uwagowe okazały się szczególnie skuteczne w grafach o heterogenicznej semantyce relacji, w tym w analizie struktur biologicznych, lingwistycznych i społecznych. Odpowiedzią na ograniczenia klasycznych GNN, w tym problem oversmoothingu oraz trudności w chwytaniu globalnych zależności, stał się w ostatnich latach (2022-2024) rozwój transformatorów grafowych (*graph transformers*), m.in. w podejściach GraphGPS oraz TokenGT (Rampásek i in., 2022; Kim i in., 2022). Modele te adaptują mechanizm samo-uwagi (*self-attention*) znany z przetwarzania języka naturalnego do struktur grafowych, umożliwiając efektywniejsze modelowanie relacji długodystansowych w sieci bez sztywnego ograniczania się do lokalnego sąsiedztwa.

Wraz z rozwojem architektur rośnie znaczenie zagadnień etyczno-prawnych w uczeniu grafowym. Złożone modele predykcyjne są podatne na zjawisko uprzedzeń algorytmicznych (*bias*). Jeżeli historyczne dane grafowe (np. sieci społecznych czy finansowych) zawierają ukryte nierówności lub błędy, modele oparte na propagacji informacji mogą je powielać, a wręcz wzmacniać. Wymusza to rozwój technik audytu grafów oraz metod uczenia sprawiedliwego (*fairness-aware graph learning*), co staje się kluczowe z punktu widzenia interpretowalności systemów AI oraz zgodności z nowymi regulacjami prawnymi.

Równolegle rozwijano podejścia indukcyjne, umożliwiające trenowanie modeli na fragmentach dużych struktur bez konieczności przetwarzania całego grafu. Architektura GraphSAGE wprowadziła koncepcję próbkowania sąsiedztwa oraz agregacji informacji na ograniczonych podgrafach, co pozwoliło skalować uczenie grafowe do struktur obejmujących miliony i miliardy wierzchołków (Hamilton i in., 2017, s. 1025). Istotną zaletą podejścia indukcyjnego jest możliwość generowania reprezentacji dla nowych, wcześniej nieobserwowanych wierzchołków, co ma kluczowe znaczenie w środowiskach dynamicznych.

Pomimo znaczących osiągnięć współczesne modele grafowe pozostają obarczone ograniczeniami teoretycznymi i obliczeniowymi. Ich ekspresywność jest ściśle powiązana z mocą testu Weisfeilera-Lehmana, co oznacza, że wiele architektur opartych na propagacji informacji nie jest w stanie odróżnić pewnych klas grafów nierozróżnialnych względem tego testu (Xu i in., 2019). Ograniczenie to wskazuje na fundamentalne bariery reprezentacyjne modeli

GNN. Dodatkowo duże grafy generują istotne obciążenie pamięciowe i obliczeniowe, co wymusza stosowanie strategii przybliżonych, technik próbkowania oraz metod hybrydowych. Modele grafowe są również wrażliwe na lokalne zmiany topologii, co może prowadzić do niestabilności reprezentacji i pogorszenia uogólniania.

Integracja algorytmów grafowych z metodami uczenia maszynowego stanowi obecnie podstawę wielu zastosowań, obejmujących bioinformatykę, chemoinformatykę, przetwarzanie języka naturalnego, analizę grafów wiedzy oraz wykrywanie anomalii w systemach komunikacyjnych. Wraz z rozwojem modeli neurosymbolicznych, metod probabilistycznych oraz architektur hybrydowych znaczenie uczenia grafowego będzie prawdopodobnie rosło, a graf pozostanie jednym z kluczowych modeli integrujących różne paradygmaty współczesnej sztucznej inteligencji.

Skalowalność i złożoność obliczeniowa w grafowych systemach dużej skali

Skalowalność algorytmów grafowych stała się jednym z kluczowych wyzwań współczesnej informatyki, ponieważ rzeczywiste grafy osiągają rozmiary, które jeszcze dwie dekady temu były niewyobrażalne. W systemach telekomunikacyjnych, mediach społecznościowych, analizach finansowych czy medycynie obliczeniowej liczba wierzchołków i krawędzi rośnie w tempie wykładniczym, co powoduje, że tradycyjne podejścia algorytmiczne, projektowane z myślą o strukturach mieszczących się w pamięci pojedynczej maszyny, stają się niewystarczające (Leskovec i in., 2020). Współczesne badania koncentrują się zatem nie tylko na analizie tych struktur, lecz także na opracowywaniu metod umożliwiających ich dynamiczne utrzymanie i przetwarzanie w warunkach ograniczonych zasobów obliczeniowych.

Istotnym czynnikiem utrudniającym skalowanie jest topologia grafów rzeczywistych, które często wykazują własności sieci bezskalnych. W takich strukturach niewielka liczba węzłów posiada bardzo wysoki stopień, podczas gdy większość pozostaje słabo połączona. Nierównomierna dystrybucja stopni prowadzi do znacznego zróżnicowania obciążeń obliczeniowych w systemach rozproszonych. Obecność wysoce połączonych wierzchołków zwiększa koszty komunikacji między węzłami obliczeniowymi oraz utrudnia równomierne partycjonowanie grafu (Newman, 2018). W praktyce oznacza to, że nawet

w dużych klastrach obliczeniowych wąskie gardła komunikacyjne mogą ograniczać efektywność przetwarzania.

Odpowiedzią na te wyzwania było rozwinięcie architektur przetwarzania rozproszonego, wśród których istotne miejsce zajmuje model *Bulk Synchronous Parallel* (BSP), zaimplementowany m.in. w systemie Pregel (Malewicz i in., 2010). W modelu tym graf dzielony jest na partycje przetwarzane równolegle, a komunikacja pomiędzy nimi odbywa się w zsynchronizowanych fazach obliczeń. Podejście to umożliwia skalowanie do miliardów węzłów, jednak koszty synchronizacji i komunikacji między partycjami stają się dominującym czynnikiem przy dalszym zwiększaniu skali.

Równolegle rozwijano metody akceleracji sprzętowej, zwłaszcza z wykorzystaniem procesorów graficznych (GPU) oraz wyspecjalizowanych jednostek obliczeniowych. GPU pozwalają na efektywne wykonywanie operacji na macierzach rzadkich, które stanowią podstawę wielu algorytmów grafowych, w tym analiz spektralnych oraz modeli głębokiego uczenia. Efektywne wykorzystanie akceleratorów wymaga jednak stosowania technik redukcji grafu, takich jak próbkowanie sąsiedztwa czy kompresja struktury (Chen i in., 2018, s. 4). Redukcje te zmniejszają koszty obliczeń, lecz mogą prowadzić do utraty części informacji topologicznej, co wymaga kompromisu między efektywnością a dokładnością.

Ważną grupę metod wspierających skalowalność stanowią techniki przybliżone, umożliwiające analizę grafów bez przetwarzania wszystkich krawędzi. Jednym z podejść jest *sparsification*, polegające na redukcji liczby krawędzi przy zachowaniu kluczowych własności spektralnych grafu. Wykazano, że nawet znacząca redukcja struktury może zachować własności istotne dla analizy przepływów czy klasteryzacji (Spielman, Srivastava, 2011). Innym podejściem jest *coarsening*, w którym grupy wierzchołków agregowane są w superwęzły, tworząc hierarchiczną reprezentację grafu. Techniki te stanowią fundament współczesnych metod wieloskalowych, w tym architektur grafowych sieci neuronowych.

W kontekście sztucznej inteligencji rośnie również znaczenie problemu stabilności reprezentacji grafowych w systemach dużej skali. Niewielkie zmiany topologiczne – takie jak dodanie krawędzi czy modyfikacja wag – mogą prowadzić do istotnych zmian w reprezentacjach generowanych przez modele uczące się. Zjawisko to wynika zarówno z własności spektralnych grafów, jak

i z dynamiki propagacji informacji w architekturach głębokiego uczenia. Analizy wskazują, że stabilność modeli grafowych jest ściśle powiązana z ich podstawą spektralną, co wyznacza kierunek dalszych badań teoretycznych i praktycznych (Gama i in., 2020).

Podsumowując, problem skalowalności algorytmów grafowych nie ogranicza się do kwestii czysto technicznych. Stanowi on jedno z centralnych wyzwań w projektowaniu infrastruktury obliczeniowej współczesnej sztucznej inteligencji. Efektywne przetwarzanie grafów o rozmiarach globalnych wymaga synergii metod teoretycznych, architektur rozproszonych, akceleracji sprzętowej oraz technik probabilistycznych i hierarchicznych. Kluczowe staje się znalezienie równowagi pomiędzy dokładnością analizy a kosztami obliczeniowymi, co bezpośrednio wpływa na praktyczną użyteczność modeli grafowych w systemach rzeczywistych.

Grafowe modele uczenia reprezentacji: perspektywa teoretyczna i geometryczna

Uczenie reprezentacji grafowych stało się jednym z najbardziej dynamicznie rozwijających się obszarów współczesnej sztucznej inteligencji. W przeciwieństwie do klasycznych metod algorytmicznych, operujących bezpośrednio na strukturze grafu, podejście to zakłada możliwość odwzorowania relacji grafowych w przestrzeni numerycznej, w której cechy strukturalne sieci przejawiają się jako wzorce geometryczne. Reprezentacja taka, określana mianem przestrzeni latentnej, stanowi podstawę dalszych operacji klasyfikacyjnych, predykcyjnych i generatywnych (Hamilton, 2020, s. 11). Kluczowa idea uczenia reprezentacji grafowych polega na identyfikowaniu wzorców zależności, które mogą być trudne do uchwycenia w przestrzeni oryginalnej struktury, lecz ujawniają się po transformacji do przestrzeni wektorowej. W ujęciu geometrycznym graf można traktować jako obiekt o własnej strukturze topologicznej, w którym relacje między wierzchołkami determinują lokalną geometrię przestrzeni reprezentacyjnej (Bronstein i in., 2021). Takie podejście umożliwia wykorzystanie narzędzi analizy geometrycznej oraz spektralnej do konstrukcji modeli zdolnych do uchwycenia złożonych relacji. Istotnym zagadnieniem pozostaje dobór przestrzeni latentnej. Przestrzenie euklidesowe, choć intuicyjne

i szeroko stosowane, nie zawsze oddają hierarchiczną naturę wielu grafów, takich jak grafy wiedzy czy sieci semantyczne. W takich przypadkach adekwatniejsze okazują się przestrzenie hiperboliczne, których ujemna krzywizna umożliwia kompaktowe modelowanie struktur drzewiastych i hierarchicznych. Wykazano, że osadzanie w przestrzeni hiperbolicznej pozwala na reprezentowanie relacji hierarchicznych przy niższym wymiarze i mniejszym błędzie rekonstrukcji niż w przestrzeniach euklidesowych (Nickel, Kiela, 2017, s. 6352).

Równolegle rozwijane są modele probabilistyczne, w których struktura grafu traktowana jest jako realizacja procesu losowego. W takim ujęciu reprezentacje uwzględniają niepewność topologii oraz zmienność relacji. Modele probabilistyczne odgrywają szczególną rolę w zastosowaniach obejmujących dane niepełne lub szumne, takich jak bioinformatyka czy analiza sieci epidemiologicznych. Integracja informacji strukturalnej z niepewnością probabilistyczną umożliwia budowę modeli bardziej odpornych na zakłócenia (Koller, Friedman, 2009).

W ostatnich latach rozwój reprezentacji grafowych objął również modele operujące na poziomie całych grafów, a nie wyłącznie pojedynczych węzłów. Techniki te wykorzystują hierarchiczne mechanizmy agregacji, które stopniowo kompresują strukturę grafu, tworząc jego reprezentację globalną. Hierarchiczne modelowanie pozwala zachować wieloskalowy charakter danych, od lokalnych motywów po globalne zależności strukturalne (Ying i in., 2018, s. 4802). Podejście to znajduje zastosowanie m.in. w chemoinformatyce oraz analizie układów biologicznych. Coraz większego znaczenia nabiera także integracja uczenia reprezentacji grafowych z podejściami neurosymbolicznymi. Łączenie modeli statystycznych z formalnymi ograniczeniami logicznymi umożliwia budowę systemów, w których graf pełni rolę struktury wiedzy podlegającej zarówno uczeniu, jak i dedukcji. Wskazuje się, że takie połączenie może prowadzić do powstania systemów sztucznej inteligencji zdolnych do integracji wnioskowania symbolicznego z reprezentacją ciągłą (Bianchi i in., 2020, s. 57).

Uczenie reprezentacji grafowych istotnie przekształciło sposób interpretacji danych relacyjnych. Przejście od analizy czysto topologicznej do ujęć geometrycznych, probabilistycznych i hierarchicznych sprawiło, że graf stał się nie tylko narzędziem opisu, lecz również mechanizmem transformacji wiedzy. Reprezentacje grafowe umożliwiają budowę modeli bardziej elastycznych,

skalowalnych i semantycznie świadomych, wyznaczając kierunek dalszego rozwoju badań nad sztuczną inteligencją opartą na strukturach relacyjnych. W celu syntetycznego uporządkowania przedstawionych klas metod grafowych oraz ich ewolucji w kontekście sztucznej inteligencji zestawiono je w Tabeli 1.

Tabela 1. Klasy metod grafowych i ich ewolucja w sztucznej inteligencji

Etap rozwoju	Klasa metod	Charakter obliczeń	Reprezentacja danych	Typowe zastosowania
I. Klasyczny	Algorytmy deterministyczne (BFS, DFS, Dijkstra, MST, Max-Flow)	Kombinatoryczne, deterministyczne	Struktura topologiczna grafu	Routing, optymalizacja, analiza sieci
II. Reprezentacyjny	Uczenie grafowe (GCN, GAT, GraphSAGE, MPNN)	Statystyczne, uczenie głębokie	Przestrzeń latentna (wektorowa)	Predykcja węzłów, klasyfikacja, chemoinformatyka
III. Geometryczny	Osadzania hiperboliczne, spektralne	Geometryczne, algebraiczne	Przestrzenie nieeuklidesowe	Modelowanie hierarchii, grafy wiedzy
IV. Hybrydowy	Modele neurosymboliczne, probabilistyczne, kwantowe	Symboliczne + statystyczne + nieklasyczne	Struktura wiedzy + reprezentacja ciągła	Systemy wiedzy, AI interpretowalna, modele przyszłościowe

Źródło: opracowanie własne.

Reprezentacje grafowe przenoszą relacje do przestrzeni latentnych, gdzie łatwiej budować modele predykcyjne, a dobór geometrii (euklidesowej vs. nieeuklidesowej) wpływa na zdolność odwzorowania hierarchii i struktury. Tak przygotowany aparat pojęciowy tłumaczy, dlaczego metody grafowe tak dobrze transferują się do zastosowań domenowych.

Zastosowania algorytmów grafowych we współczesnej informatyce i nauce o danych

Algorytmy grafowe zajmują centralne miejsce we współczesnej informatyce ze względu na zdolność modelowania złożonych zależności charakterystycznych dla dzisiejszych systemów technologicznych i naukowych. Wraz z rozwojem infrastruktury cyfrowej, eksplozją danych oraz intensyfikacją badań nad systemami inteligentnymi grafy stały się podstawowym narzędziem

opisu procesów, których nie sposób adekwatnie ująć w modelach sekwencyjnych lub tabelarycznych. Ich zastosowania wykraczają daleko poza klasyczne sieci komunikacyjne i obejmują dziedziny, w których struktura relacji stanowi kluczowy wymiar informacji.

W obszarze przetwarzania języka naturalnego grafy umożliwiły przejście od analizy liniowej do analizy strukturalnej. Reprezentacje grafowe pozwalają modelować zależności składniowe, semantyczne oraz dyskursywne, ujmując tekst jako strukturę powiązań pomiędzy jednostkami językowymi. Wykazano, że takie podejście umożliwia dokładniejsze odwzorowanie kontekstu oraz relacji logicznych w tekście (Manning, Schütze, 1999). Grafowe modele zależności znajdują zastosowanie zarówno w systemach ekstrakcji informacji, jak i w analizie wiedzy reprezentowanej w formie grafów semantycznych. Systemy rekomendacyjne należą również do ważnych obszarów zastosowań algorytmów grafowych. W tym kontekście grafy modelują relacje pomiędzy użytkownikami, produktami oraz historią interakcji, a sieci neuronowe na grafach wspierają personalizację i predykcję preferencji użytkowników (Wu i in., 2022).

Równie istotne zastosowania tych metod występują w medycynie oraz biologii obliczeniowej. Struktury grafowe stanowią naturalny model interakcji molekularnych, sieci regulacyjnych oraz procesów metabolicznych. Wykazano, że organizmy żywe funkcjonują jako systemy sieciowe, w których zaburzenia chorobowe mogą być interpretowane jako zmiany w topologii grafu, a nie wyłącznie jako defekty pojedynczych elementów (Barabási, 2016). Tego rodzaju podejście umożliwia identyfikację kluczowych węzłów regulacyjnych oraz projektowanie terapii ukierunkowanych na strukturalne właściwości sieci biologicznych. W chemoinformatyce grafy atomowe stanowią podstawę predykcji właściwości cząsteczek, co znajduje bezpośrednie zastosowanie w projektowaniu leków oraz nowych materiałów (Gilmer i in., 2017). Spektakularnym przykładem w biologii obliczeniowej jest system AlphaFold (*Google DeepMind*), który zrewolucjonizował przewidywanie struktur białek, modelując relacje przestrzenne aminokwasów za pomocą reprezentacji grafowych (Jumper i in., 2021). W projektowaniu leków modele oparte na grafach doprowadziły m.in. do odkrycia halicyny – innowacyjnego antybiotyku wytypowanego z ogromnych baz związków chemicznych (Stokes i in., 2020).

W cyberbezpieczeństwie grafy umożliwiają analizę złożonych relacji w systemach o wysokiej dynamice i dużej skali. Modelowanie zdarzeń

w postaci struktur grafowych znajduje zastosowanie w systemach wykrywania włamań, ponieważ pozwala ujmować zależności pomiędzy hostami, procesami, przepływami i zdarzeniami systemowymi w sposób trudny do osiągnięcia metodami tabelarycznymi (Zhong i in., 2024). Takie podejście wspiera identyfikację wieloetapowych incydentów oraz relacji pomiędzy pozornie odrębnymi zdarzeniami. Dzięki temu możliwe staje się budowanie systemów bezpieczeństwa zdolnych nie tylko do reakcji, lecz również do predykcji potencjalnych konsekwencji incydentów. W praktyce inżynierskiej podejście to realizowane jest poprzez tworzenie tzw. grafów pochodzenia (*provenance graphs*), które umożliwiają detekcję zaawansowanych ataków typu APT (*advanced persistent threats*). Systemy te śledzą wielomiesięczne trajektorie działań intruzów – od początkowej infekcji po eksfiltrację danych – wiążąc z pozoru niezwiązane zdarzenia w spójną sieć zależności.

W telekomunikacji grafy wykorzystywane są do modelowania infrastruktury sieciowej, przepływu danych oraz zależności pomiędzy komponentami systemów 5G i 6G. Dynamiczny charakter tych sieci wymaga stosowania algorytmów adaptacyjnych, zdolnych do bieżącej optymalizacji trasowania i alokacji zasobów. W tym kontekście rośnie znaczenie modeli GNN wspierających optymalizację routingu w sieciach komunikacyjnych nowej generacji (Jiang i in., 2024). Znaczenie tych metod rośnie szczególnie w kontekście Internetu Rzeczy, w którym miliardy urządzeń tworzą struktury o silnie złożonej topologii.

Przedstawione przykłady ukazują, że grafy przestały pełnić wyłącznie rolę formalnego modelu matematycznego. Stały się one integralnym elementem praktyki inżynierskiej i naukowej, umożliwiającym analizę relacji, hierarchii, zależności temporalnych i semantycznych w systemach o wysokim stopniu złożoności. Wraz z dalszym rozwojem technologii oraz rosnącą dostępnością danych strukturalnych można oczekiwać, że zakres zastosowań metod grafowych będzie się rozszerzał, prowadząc do powstawania nowych modeli analitycznych i predykcyjnych opartych na strukturach relacyjnych.

Nowe kierunki badań w algorytmach grafowych i perspektywy rozwoju

Współczesny rozwój algorytmów grafowych wchodzi w fazę, którą można określić jako przejście od metod czysto analitycznych do podejść

hybrydowych, integrujących elementy statystyki, logiki, geometrii oraz obliczeń nieklasycznych. Podczas gdy wcześniejsze dekady badań koncentrowały się przede wszystkim na optymalizacji algorytmów deterministycznych, obecnie centralnym zagadnieniem staje się modelowanie złożonych, wielowarstwowych i dynamicznych zależności relacyjnych w sposób adekwatny do charakteru współczesnych danych. W tym ujęciu algorytmy grafowe przestają być wyłącznie narzędziem rozwiązywania problemów kombinatorycznych, a stają się fundamentem systemów integrujących reprezentacje symboliczne, probabilistyczne i geometryczne (Hamilton, 2020).

Jednym z najważniejszych kierunków rozwoju pozostaje integracja analizy grafowej z metodami neurosymbolicznymi. Podejścia te łączą formalne struktury wiedzy z elastycznością modeli uczących się, umożliwiając jednocześnie wnioskowanie dedukcyjne oraz uogólnianie na podstawie danych empirycznych. W takich systemach graf pełni rolę strukturalnego nośnika wiedzy, natomiast reguły logiczne działają jako ograniczenia kształtujące proces uczenia. Wskazuje się, że integracja ta może prowadzić do powstawania modeli bardziej interpretowalnych i kontrolowalnych, co ma szczególne znaczenie w obszarach wymagających wysokiej wiarygodności decyzji, takich jak medycyna, prawo czy systemy bezpieczeństwa (Bianchi i in., 2020, s. 57).

Równolegle rozwijane są badania nad wykorzystaniem grafów w kontekście obliczeń kwantowych. Struktury grafowe stanowią naturalny model zależności pomiędzy kubitami oraz elementami obwodów kwantowych. Wykazano, że własności spektralne grafów mogą być odwzorowywane w przestrzeniach Hilberta, co otwiera możliwość konstrukcji kwantowych metod analizy widmowej oraz potencjalnego przyspieszenia problemów takich jak klasteryzacja, wykrywanie społeczności czy analiza przepływów (Biamonte i in., 2017). Choć obecny poziom rozwoju technologii kwantowych ogranicza praktyczne zastosowania tych metod, coraz wyraźniej rysuje się perspektywa systemów hybrydowych, w których klasyczne algorytmy grafowe współdziałają z komponentami kwantowymi.

W szerszej perspektywie przyszłość algorytmów grafowych wiąże się z dalszą integracją różnych paradygmatów obliczeniowych. Obejmuje to rozwój modeli łączących uczenie reprezentacji z formalnymi strukturami wiedzy, eksplorację przestrzeni nieeuklidesowych w modelowaniu hierarchii oraz projektowanie architektur zdolnych do efektywnego działania w warunkach

ekstremalnej skali i dynamiki danych. Graf staje się w tym kontekście nie tylko strukturą danych, lecz ogólnym językiem opisu złożoności, pozwalającym łączyć podejścia symboliczne, probabilistyczne i geometryczne w spójnych ramach obliczeniowych.

Perspektywy rozwoju wskazują zatem, że algorytmy grafowe będą odgrywać rolę integratora paradygmatów sztucznej inteligencji. Ich znaczenie nie ograniczy się do konkretnej klasy problemów, lecz będzie dotyczyć sposobu reprezentowania, przetwarzania i transformacji wiedzy w systemach o rosnącej złożoności. Kierunki rozwoju przesuwają ciężar z algorytmiki „czysto analitycznej” w stronę podejść hybrydowych: neurosymboliki, metod probabilistycznych oraz rozwiązań inspirowanych obliczeniami kwantowymi. O dalszym upowszechnieniu zdecydują: interpretowalność, skalowalność oraz stabilność modeli w warunkach danych dynamicznych i niepewnych.

Podsumowanie i perspektywy integracji metod grafowych w rozwoju współczesnej sztucznej inteligencji

Wraz z rozwojem systemów sztucznej inteligencji grafy przestały pełnić rolę pomocniczego narzędzia opisu struktury i stały się jednym z kluczowych konstruktów teoretycznych umożliwiających integrację różnorodnych metod analizy danych. Transformacja ta nie wynika wyłącznie ze wzrostu ilości danych relacyjnych, lecz z głębszej zmiany paradygmatu – przejścia od przetwarzania izolowanych obiektów do modelowania systemów zależności. Współczesne modele sztucznej inteligencji funkcjonują jako komponenty złożonych systemów poznawczych, w których struktura relacji między elementami wyznacza możliwe ścieżki wnioskowania i uogólniania (Leskovec i in., 2020). W tym kontekście graf staje się jednym z nielicznych formalizmów zdolnych jednocześnie opisywać dynamikę danych i mechanizmy ich transformacji w wiedzę. Centralnym elementem współczesnego podejścia do inteligencji obliczeniowej jest integracja perspektyw symbolicznych, statystycznych i geometrycznych. Grafy umożliwiają zbudowanie wspólnej przestrzeni, w której te trzy warstwy mogą współistnieć i wzajemnie się uzupełniać. Warstwa symboliczna ujawnia się w strukturach wiedzy, ontologiach i regułach zależności; warstwa statystyczna w procesach uczenia reprezentacji oraz modelach probabilistycznych;

warstwa geometryczna w przestrzeniach latentnych, w których odwzorowywane są struktury grafowe. Integracja tych wymiarów pozwala budować systemy nie tylko wykrywające wzorce, lecz także nadające im znaczenie semantyczne oraz zdolne do transferu wiedzy na nowe konteksty (Russell, Norvig, 2021).

Rozwój algorytmów grafowych odzwierciedla zmianę kierunku przepływu wiedzy pomiędzy teorią a zastosowaniami. O ile klasyczna teoria grafów rozwijała się głównie w oparciu o abstrakcyjne analizy matematyczne, współczesne potrzeby aplikacyjne – obejmujące analizę struktur molekularnych, modelowanie relacji temporalnych czy przetwarzanie danych multimodalnych – wymuszają powstawanie nowych narzędzi teoretycznych. Statystyka strukturalna, analiza spektralna oraz współczesne modele uczenia grafowego coraz częściej funkcjonują nie jako odrębne dziedziny, lecz jako wzajemnie powiązane elementy jednego ekosystemu metod analizy danych relacyjnych (Hamilton, 2020; Zhang i in., 2020). W tym ujęciu graf pełni rolę elementu scalającego. Pozwala on jednocześnie operować na poziomie lokalnych relacji i globalnych własności systemu, a także modelować zarówno strukturę danych, jak i dynamikę procesów obliczeniowych. W wielu współczesnych podejściach graf staje się metastrukturą, w której zakodowane są relacje między jednostkami wiedzy, ograniczenia logiczne oraz ścieżki inferencyjne. Zjawisko to jest szczególnie widoczne w systemach neurosymbolicznych i w dynamicznych grafach wiedzy, gdzie struktura i proces uczenia współdeterminują zachowanie modelu (Besold i in., 2017).

W wymiarze praktycznym grafy umożliwiają integrację heterogenicznych typów danych – od sekwencji i obrazów po sygnały przestrzenne i informacje semantyczne – w ramach jednej struktury relacyjnej. Pozwala to budować systemy wielowarstwowego wnioskowania, w których graf organizuje przepływ informacji pomiędzy różnymi modalnościami. Takie podejście zwiększa zarówno skalowalność, jak i precyzję modeli predykcyjnych, szczególnie w zastosowaniach wymagających łączenia wiedzy strukturalnej i kontekstowej (Zhang i in., 2020). Ostatecznie rozwój algorytmów grafowych prowadzi do nowego rozumienia relacyjności w sztucznej inteligencji. Graf nie jest już jedynie strukturą danych ani narzędziem analizy topologicznej. Staje się uniwersalnym językiem opisu złożoności, w którym integrują się paradygmaty symboliczne, probabilistyczne i geometryczne. Wraz z rozwojem metod neurosymbolicznych, systemów dynamicznych oraz architektur hybrydowych – w tym

rozwiązań wykorzystujących obliczenia kwantowe – grafy będą odgrywać rolę podstawowego modelu organizującego wiedzę i procesy obliczeniowe. W tym sensie przyszłość badań nad sztuczną inteligencją w coraz większym stopniu będzie przyszłością metod grafowych.

Literatura

1. Barabási, A.-L. (2016). *Network science*. Cambridge University Press.
2. Bellman, R. (1958). On a routing problem. *Quarterly of Applied Mathematics*, 16(1), 87-90. <https://doi.org/10.1090/qam/102435>
3. Besold, T. R., d'Avila Garcez, A., Bader, S., Bowman, H., Domingos, P., Hitzler, P., Kühnberger, K.-U., Lamb, L. C., Lowd, D., Machado Vieira Lima, P., de Penning, L., Pinkas, G., Poon, H., Zaverucha, G. (2017). Neural-symbolic learning and reasoning: a survey and interpretation. *arXiv*, 1711.03902. <https://doi.org/10.48550/arXiv.1711.03902>
4. Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N., Lloyd, S. (2017). Quantum machine learning. *Nature*, 549, 487489. <https://doi.org/10.1038/nature23474>
5. Bronstein, M. M., Bruna, J., LeCun, Y., Szlam, A., Vandergheynst, P. (2017). Geometric deep learning: Going beyond Euclidean data. *IEEE Signal Processing Magazine*, 34(4), 18-42. <https://doi.org/10.1109/MSP.2017.2693418>
6. Bronstein, M. M., Bruna, J., Cohen, T., Veličković, P. (2021). *Geometric deep learning: Grids, groups, graphs, geodesics, and gauges*. MIT Press.
7. Chen, J., Ma, T., Xiao, C. (2018). FastGCN: Fast learning with graph convolutional networks via importance sampling. In *Proceedings of the International Conference on Learning Representations (ICLR)*. *arXiv*. 1801.10247. <https://arxiv.org/abs/1801.10247>
8. Chung, F. R. K. (1997). *Spectral graph theory*. American Mathematical Society. <https://doi.org/10.1090/cbms/092>
9. Cormen, T. H., Leiserson, C. E., Rivest, R. L., Stein, C. (2022). *Introduction to algorithms* (4th ed.). MIT Press.
10. Bianchi, F., Rossiello, G., Costabello, L., Palmonari, M., Minervini, P. (2020). Knowledge graph embeddings and explainable AI. W: I. Tiddi, F. Lécué, P. Hitzler (red.), *Knowledge graphs for eXplainable artificial intelligence: Foundations, applications and challenges* (s. 49-72). IOS Press. <https://doi.org/10.3233/SSW200011>

11. Diestel, R. (2018). *Graph theory* (5th ed.). Springer. <https://doi.org/10.1007/978-3-662-53622-3>
12. Dijkstra, E. W. (1959). A note on two problems in connexion with graphs. *Numerische Mathematik*, 1, 269-271. <https://doi.org/10.1007/BF01386390>
13. Ford, L. R., Jr., Fulkerson, D. R. (1962). *Flows in networks*. Princeton University Press. <https://doi.org/10.1515/9781400875184>
14. Gama, F., Isufi, E., Leus, G., Ribeiro, A. (2020). Graphs, Convolutions, and Neural Networks: From Graph Filters to graph neural networks. *IEEE Signal Processing Magazine*, 37(6), 128-138. <https://doi.org/10.1109/MSP.2020.3016143>
15. Gilmer, J., Schoenholz, S. S., Riley, P. F., Vinyals, O., Dahl, G. E. (2017). Neural message passing for quantum chemistry. *arXiv*, 1704.01212. <https://doi.org/10.48550/arXiv.1704.01212>
16. Hamilton, W. L. (2020). *Graph representation learning*. Morgan & Claypool. <https://doi.org/10.2200/s01045ed1v01y202009aim046>
17. Hamilton, W. L., Ying, Z., Leskovec, J. (2017). Inductive representation learning on large graphs. *arXiv*, 1706.02216. <https://doi.org/10.48550/arXiv.1706.02216>
18. Jiang, W., Han, H., Zhang, Y., Wang, J., He, M., Gu, W., Mu, J., Cheng, X. (2024). Graph neural networks for routing optimization: challenges and opportunities. *Sustainability*, 16(21), 9239. <https://doi.org/10.3390/su16219239>
19. Jumper, J., Evans, R., Pritzel, A., Green, T., Figurnov, M., Ronneberger, O., Tunyasuvunakool, K., Bates, R., Židek, A., Potapenko, A., Bridgland, A., Meyer, C., Kohl, S. A. A., Ballard, A. J., Cowie, A., Romera-Paredes, B., Nikolov, S., Jain, R., Adler, J. (...), Hassabis, D. (2021). Highly accurate protein structure prediction with AlphaFold. *Nature*, 596, 583-589. <https://doi.org/10.1038/s41586-021-03819-2>
20. Kim, J., Nguyen, T. D., Min, S., Cho, S., Lee, M., Lee, H., Hong, S. (2022). Pure transformers are powerful graph learners. *arXiv*, 2207.02505. <https://doi.org/10.48550/arXiv.2207.02505>
21. Kipf, T. N., Welling, M. (2017). Semi-supervised classification with graph convolutional networks. *arXiv*, 1609.02907. <https://doi.org/10.48550/arXiv.1609.02907>
22. Koller, D., Friedman, N. (2009). *Probabilistic graphical models: Principles and techniques*. MIT Press.

23. Kruskal, J. B. (1956). On the shortest spanning subtree of a graph and the traveling salesman problem. *Proceedings of the American Mathematical Society*, 7, 48-50. <https://doi.org/10.2307/2033241>
24. Leskovec, J., Rajaraman, A., Ullman, J. D. (2020). *Mining of massive datasets* (3rd ed.). Cambridge University Press.
25. Malewicz, G., Austern, M. H., Bik, A. J. C., Dehnert, J. C., Horn, I., Leiser, N., Czajkowski, G. (2010). Pregel: A system for large-scale graph processing. W: *Proceedings of the 2010 ACM SIGMOD International Conference on Management of Data* (s. 135-146). Association for Computing Machinery. <https://doi.org/10.1145/1807167.1807184>
26. Manning, C. D., Schütze, H. (1999). *Foundations of statistical natural language processing*. MIT Press.
27. Newman, M. (2018). *Networks* (2nd ed.). Oxford University Press.
28. Nickel, M., Kiela, D. (2017). Poincaré embeddings for learning hierarchical representations. *arXiv*, 1705.08039. <https://doi.org/10.48550/arXiv.1705.08039>
29. Rampášek, L., Galkin, M., Dwivedi, V. P., Luu, A. T., Wolf, G., Beaini, D. (2022). Recipe for a general, powerful, scalable graph transformer. *arXiv*, 2205.12454. <https://doi.org/10.48550/arXiv.2205.12454>
30. Russell, S., Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
31. Spielman, D. A., Srivastava, N. (2011). Graph sparsification by effective resistances. *SIAM Journal on Computing*, 40(6), 1913-1926. <https://doi.org/10.1137/080734029>
32. Stokes, J. M., Yang, K., Swanson, K., Jin, W., Cubillos-Ruiz, A., Donghia, N. M., MacNair, C. R., French, S., Carfrae, L. A., Bloom-Ackermann, Z., Tran, V. M., Chiappino-Pepe, A., Badran, A. H., Andrews, I. W., Chory, E. J., Church, G. M., Brown, E. D., Jaakkola, T. S., Barzilay, R., Collins, J. J. (2020). A deep learning approach to antibiotic discovery. *Cell*, 180(4), 688-702.e13. <https://doi.org/10.1016/j.cell.2020.01.021>
33. Veličković, P., Cucurull, G., Casanova, A., Romero, A., Liò, P., Bengio, Y. (2018). Graph attention networks. *arXiv*, 1710.10903. <https://doi.org/10.48550/arXiv.1710.10903>
34. Wu, S., Sun, F., Zhang, W., Xie, X., Cui, B. (2022). Graph neural networks in recommender systems: A survey. *ACM Computing Surveys*, 55(5), 97. <https://doi.org/10.1145/3535101>

35. Xu, K., Hu, W., Leskovec, J., Jegelka, S. (2019). How powerful are graph neural networks?. *arXiv*, 1810.00826. <https://doi.org/10.48550/arXiv.1810.00826>
36. Ying, Z., You, J., Morris, C., Ren, X., Hamilton, W. L., Leskovec, J. (2018). Hierarchical graph representation learning with differentiable pooling. *arXiv*, 1806.08804. <https://doi.org/10.48550/arXiv.1806.08804>
37. Zhang, Z., Cui, P., Zhu, W. (2022). Deep learning on graphs: A survey. *IEEE Transactions on Knowledge and Data Engineering*, 34(1), 249-270. <https://doi.org/10.1109/TKDE.2020.2981333>
38. Zhong, M., Lin, M., Zhang, C., Xu, Z. (2024). A Survey on Graph Neural Networks for Intrusion Detection Systems: Methods, Trends and Challenges. *Computers & Security*, 141, 103821. <https://doi.org/10.1016/j.cose.2024.103821>

dr inż. Katarzyna Łacka¹

Akademia Bialska im. Jana Pawła II, Biała Podlaska

Agnieszka Hołonowicz

Fundacja im. Leśława A. Pagi, Warszawa

INTEGRACJA AI I ZRÓWNOWAŻONEGO ROZWOJU – PERSPEKTYWY I WYZWANIA W ROLNICTWIE

INTEGRATION OF AI AND SUSTAINABLE DEVELOPMENT – PERSPECTIVES AND CHALLENGES IN AGRICULTURE

Streszczenie

Dynamiczny rozwój technologii cyfrowych sprawia, że sztuczna inteligencja (AI) staje się jednym z kluczowych narzędzi transformacji współczesnego rolnictwa. Zastosowanie systemów bazujących na algorytmach sztucznej inteligencji umożliwia automatyzację, precyzyjne monitorowanie upraw, poprawę dobrostanu zwierząt oraz bardziej świadome gospodarowanie zasobami naturalnymi. W obliczu wyzwań związanych ze zmianami klimatycznymi, degradacją środowiska i rosnącym zapotrzebowaniem na żywność, AI zyskuje strategiczne znaczenie we wdrażaniu zasad zrównoważonego rozwoju. Technologie, obejmujące uczenie maszynowe, analizę danych, systemy wizyjne i Internet Rzeczy (IoT), tworzą nowe możliwości optymalizacji produkcji rolniczej. Mimo licznych korzyści proces wdrażania sztucznej inteligencji wiąże się także z wyzwaniami. Wyzwania te dotyczą: wysokich kosztów inwestycyjnych, konieczności zapewnienia odpowiedniej infrastruktury technicznej i łączności, skomplikowanych

¹ <https://orcid.org/0009-0001-4656-5635>, e-mail: k.lacka@dyd.akademiabialska.pl
Łacka, K., Hołonowicz, A. (2026). Integracja AI i zrównoważonego rozwoju – perspektywy i wyzwania w rolnictwie. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 44-53). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_3

systemów cyfrowych oraz ryzyka wykluczenia technologicznego części producentów. Celem pracy jest przedstawienie możliwości zastosowania sztucznej inteligencji w procesie wspierania zrównoważonego rolnictwa, ze szczególnym uwzględnieniem monitorowania upraw, dobrostanu zwierząt oraz wyzwań infrastrukturalnych i społecznych związanych z wdrażaniem nowoczesnych technologii.

Słowa kluczowe: sztuczna inteligencja, zrównoważony rozwój, zrównoważone rolnictwo, automatyzacja rolnictwa

Abstract

The dynamic development of digital technologies means that artificial intelligence (AI) is becoming one of the key tools for transforming modern agriculture. The use of systems based on AI algorithms enables automation, precise crop monitoring, improved animal welfare, and more conscious management of natural resources. In the face of challenges related to climate change, environmental degradation and growing demand for food, AI is gaining strategic importance in the implementation of sustainable development principles. The dynamic development of digital technologies, including machine learning, data analytics, vision systems and the Internet of Things (IoT), is creating new opportunities for optimising agricultural production. Despite its many benefits, the implementation of AI also presents challenges. These include high investment costs, the need to ensure adequate technical and communications infrastructure, the complexity of integrating digital systems, and the risk of technological exclusion of some producers. The aim of this study is to present the possibilities of applying AI to support sustainable agriculture, with particular emphasis on crop monitoring, animal welfare, and the infrastructural and social challenges associated with the implementation of modern technologies.

Keywords: artificial intelligence, sustainable development, sustainable agriculture, agricultural automation

Wstęp

Dynamiczny rozwój technologii cyfrowych sprawił, że sztuczna inteligencja (AI) stała się głównym motorem zmian we współczesnej gospodarce. AI umożliwia automatyczne gromadzenie i analizę danych, usprawnia procesy decyzyjne oraz przyspiesza rozwój wielu gałęzi gospodarki, również rolnictwa. Rozwój sektora rolnictwa jest nierozdzielnie związany z szeregiem kluczowych obszarów, takich jak kwestie społeczne, zdrowie publiczne, funkcjonowanie

ekosystemów czy gospodarowanie zasobami naturalnymi. Współczesne rolnictwo boryka się ze zmianami klimatycznymi, degradacją gleb, rosnącym zapotrzebowaniem na zdrową żywność i optymalnej jakości paszę oraz problemami z zachowaniem bioróżnorodności. Czynniki te sprzyjają integracji postępu technologicznego z zasadami zrównoważonego rozwoju (Kwasek i in., 2023).

Rewolucja cyfrowa obejmująca sektor rolniczy dotyczy optymalizacji zabiegów agrotechnicznych, stabilności ekonomicznej, oddziaływania na środowisko rolnicze oraz wprowadzania innowacyjnych rozwiązań w chowie zwierząt. Rolnicy przy użyciu systemów bazujących na algorytmach AI mogą optymalizować zarządzanie gospodarstwem, monitorować zwierzęta i wpłynąć na zachowanie bioróżnorodności krajobrazu rolniczego (Różanowski, 2007). Algorytmy uczenia maszynowego na podstawie poznanych wzorców umożliwiają prognozę plonów, identyfikację chorób i szkodników w produkcji roślinnej oraz analizę pogody (Kamilaris, Prenafeta-Boldu, 2018a; Shah i in., 2020).

AI stanowi istotny element tzw. czwartej rewolucji przemysłowej. Zastosowanie technologii z wykorzystaniem sztucznej inteligencji ułatwia podejmowanie decyzji, usprawnia procesy produkcyjne oraz wprowadza nowe modele zarządzania zasobami. AI może znacząco uprościć zapewnianie zgodności z regulacjami oraz dostarczać organizacjom praktycznych, aktualnych informacji, pozwalając podejmować szybsze i bardziej trafne decyzje. Organizacja Współpracy Gospodarczej i Rozwoju definiuje sztuczną inteligencję jako „system oparty na maszynach, który w celu osiągnięcia wyraźnych lub domyślnych celów na podstawie otrzymanych danych wejściowych wnioskuje, w jaki sposób generować dane wyjściowe, takie jak prognozy, treści, zalecenia lub decyzje, które mogą wpływać na środowisko fizyczne lub wirtualne” (Grobelnik, Per-set, Russel, 2024). Sztuczna inteligencja staje się narzędziem wspierającym transformację rolnictwa w kierunku „inteligentnej i zielonej produkcji żywności”. Połączenie wykorzystania AI w procesie zrównoważonego podejścia do produkcji żywności to symbioza z zasadami efektywności energetycznej, etyki oraz odpowiedzialności środowiskowej. W tym kontekście coraz większego znaczenia nabiera koncepcja zrównoważonego rozwoju, której celem jest harmonijne łączenie wzrostu gospodarczego z ochroną środowiska i dobrobytem społecznym. Integracja sztucznej inteligencji z ideą zrównoważonego rozwoju staje się jednym z priorytetów rolnictwa (Prokopowicz, 2025). Kompleksowe gospodarowanie na podstawie racjonalności ekonomicznej, ochrony

środowiska oraz wdrażania innowacyjności w sektorze rolniczym to kluczowe wyzwania współczesnego rolnictwa (Sanyaolu, Sadowski, 2024).

Sztuczna inteligencja a zrównoważone rolnictwo

Rolnictwo stanowi obszar, w którym zastosowanie AI może przynieść wymierne korzyści dla zrównoważonego gospodarowania zasobami. Technologie analizy dużych zbiorów danych, systemy wizyjne, teledetekcja czy Internet rzeczy (IoT) umożliwiają precyzyjne monitorowanie upraw i zwierząt gospodarskich, optymalizację zużycia wody i pasz, redukcję stosowania środków chemicznych oraz poprawę dobrostanu zwierząt (Such-Pyrgiel i in., 2022). Zrównoważone podejście do rolnictwa cechuje ochrona środowiska naturalnego jednocześnie z uzyskaniem celów oczekiwanych w produkcji rolnej. Rolnictwo, jako jeden z kluczowych sektorów gospodarki, ma wpływ nie tylko na bezpieczeństwo żywnościowe, lecz także na stan środowiska naturalnego, jakość życia społeczeństwa oraz stabilność ekonomiczną – zarówno w skali lokalnej, jak i globalnej. W obliczu narastających wyzwań związanych ze zmianami klimatycznymi, kurczącymi się zasobami naturalnymi oraz pogłębiającymi się nierównościami społecznymi, konieczne staje się wypracowanie i wdrożenie nowych perspektyw rozwoju (Klusek i in., 2023).

Rozwój sektora rolnictwa jest nierozdzielnie związany z szeregiem kluczowych obszarów, takich jak kwestie społeczne, zdrowie publiczne, zmiany klimatyczne, dostęp do energii, funkcjonowanie ekosystemów czy gospodarowanie zasobami naturalnymi. Wszystkie wyodrębnione elementy wymagają precyzyjnego zdefiniowania w formie konkretnych celów. Cele te umożliwią ukierunkowanie działań na osiągnięcie zrównoważonego rozwoju. W perspektywie powinny one umożliwić przekształcenie rolnictwa w sektor bardziej zrównoważony, efektywny i zdolny sprostać potrzebom ludności dbając o zapewnienie bezpieczeństwa żywności oraz stabilności ekosystemów (Thornhill i in., 2016). Oznacza to dążenie do maksymalizacji produkcji przy jednoczesnym ograniczaniu negatywnego wpływu rolnictwa na środowisko naturalne (Tian i in., 2021). Systemy bazujące na algorytmach AI w przyszłości mogą odegrać pierwszoplanową rolę w zarządzaniu zasobami naturalnymi, w tym w monitorowaniu i przewidywaniu zużycia wody w rolnictwie (Aliyu, Liu, 2023). Dane pochodzące z różnych źródeł, zarówno z czujników rozmieszczonych na polach

uprawnych, jak i w budynkach inwentarskich są gromadzone, przechowywane i przetwarzane w czasie rzeczywistym (Kamilaris i in., 2017). Analiza obrazów w połączeniu z algorytmami sztucznej inteligencji umożliwia wykrywanie anomalii w wielu obszarach rolnictwa. Popularne techniki analizy obrazu obejmują uczenie maszynowe oraz wskaźniki wegetacji (takie jak NDVI). Zastosowanie tych metod pozwala między innymi na: wykrywanie chorób roślin, rozpoznawanie gatunków roślin, liczenie owoców, identyfikację chwastów, przewidywanie plonów oraz monitorowanie stanu zdrowia zwierząt. Co istotne, techniki te pozostają skuteczne mimo zmiennych warunków oświetleniowych, zróżnicowanego tła oraz odmiennych orientacji obrazów (Amara i in., 2017).

W obliczu narastających wyzwań związanych ze zmianami klimatycznymi, ograniczonymi zasobami naturalnymi czy narastającymi nierównościami społecznymi konieczne staje się wypracowanie i wdrożenie perspektyw, które umożliwią zachowanie zasad zrównoważonego rolnictwa.

Sztuczna inteligencja a dobrostan zwierząt

Wśród innowacji z wykorzystaniem sztucznej inteligencji wyróżnia się rewolucyjne podejście w zachowaniu dobrostanu zwierząt. Dostarczanie informacji na temat zdrowia, stanu oraz kondycji krów odbywa się przez monitorowanie bydła. Monitoring każdej sztuki bydła umożliwia wczesne reagowanie na wszelkie występujące anomalie w zachowaniu zwierząt (Neethirajan, 2023). Krowy są monitorowane w czasie rzeczywistym na podstawie unikalnych cech biometrycznych. Technologia biometrycznego rozpoznawania, np. głów krów, oparta na zaawansowanych metodach uczenia głębokiego i sieciach neuronowych (CNN), umożliwia precyzyjną identyfikację zwierząt. Identyfikacja bydła polega na obserwacji i analizie konkretnych cech ciała zwierzęcia. Wśród cech charakteryzujących głowę zwierzęcia można wyróżnić różnice w kształcie oczu, pigmentacji, wielkości nozdrzy czy umaszczeniu (Mahato, Neethirajan, 2025). Oprócz charakterystyki cech biometrycznych przetwarzane są nagrania wideo, umożliwiające monitorowanie ruchu i zachowania zwierząt (Dhaliwal i in., 2025). Informacje na temat zachowania oraz zmian w zachowaniu zwierząt umożliwiają ocenę ich stanu zdrowia, a tym samym wydajności zwierzęcia (Mahato, Neethirajan, 2025). Adaptacja technologii biometrycznego rozpoznawania głów u krów mlecznych to proces złożony, lecz potencjalnie niezwykle

korzystny dla nowoczesnych gospodarstw. Wymaga on charakterystyki cech anatomicznych zwierząt, ich naturalnych zachowań oraz warunków środowiskowych panujących w oborze. Konieczna jest także integracja zaawansowanych komponentów technologicznych, obejmujących systemy rejestracji obrazu, jednostki przetwarzania danych oraz narzędzi analitycznych opartych na sztucznej inteligencji (Sztandarski i in., 2025). W tym kontekście niezwykle użyteczny staje się multimedialny, zintegrowany system monitorowania bydła. Takie rozwiązania umożliwiają integrację różnych strumieni danych, takich jak obrazy z kamer, dane z czujników IoT oraz wyniki zaawansowanej analizy, w ramach jednej platformy wspomagającej proces podejmowania decyzji w gospodarstwie rolnym. System ten pozwala na precyzyjne monitorowanie dobrostanu, zdrowia i wydajności krów mlecznych, znacząco podnosząc efektywność zarządzania stadem (Parivendan, Sailunaz, Neethirajan, 2025).

AI i zrównoważone rolnictwo – wyzwania

W procesie dążenia do zrównoważonego rozwoju rolnictwa, w konsekwencji wprowadzania zaawansowanych technologii pojawia się szereg trudności oraz wyzwań. Wyzwania te obejmują obszar: ekonomiczny, społeczny i środowiskowy. Dziedziny te pozostają ze sobą ściśle powiązane np. ograniczenia ekonomiczne wpływają na możliwości wdrażania technologii przyjaznych środowisku, a presja społeczna może determinować kierunki polityki rolnej. Z tego powodu skuteczna analiza oraz poszukiwanie optymalnych rozwiązań wymagają podejścia interdyscyplinarnego, obejmującego zarówno nauki przyrodnicze, ekonomiczne, techniczne, jak i społeczne. Tylko integracja różnorodnych perspektyw pozwala zrozumieć złożoność współczesnych systemów żywnościowych oraz projektować strategie, które równocześnie wspierają równowagę środowiska, bezpieczeństwo ekonomiczne producentów i potrzeby społeczeństwa (Kamilaris, Prenafeta-Boldú, 2018b). W odpowiedzi na te problemy konieczne jest wdrażanie nowoczesnych, udoskonalonych metod gospodarowania oraz innowacyjnych praktyk rolniczych, które pozwolą zwiększyć efektywność produkcji, a jednocześnie utrzymać wysoki poziom zrównoważenia całego sektora (Kostina-Bednarz i in., 2023).

Mimo wielu korzyści wynikających z zastosowania sztucznej inteligencji w sektorze rolnictwa jej wdrażanie wiąże się także z istotnymi ograniczeniami.

Dotyczą one etyki, dostępności innowacji oraz wpływu technologii cyfrowych na środowisko naturalne.

Dotyczy to zwłaszcza rosnącego zapotrzebowania na energię, konieczności rozbudowy infrastruktury cyfrowej oraz związanego z tym śladu węglowego. Odpowiedzialne wdrażanie sztucznej inteligencji wymaga zatem uwzględnienia nie tylko jej potencjału, lecz także kosztów środowiskowych i społecznych (Toorajipour i in., 2021).

Jednym z głównych wyzwań jest koszt wdrożenia nowych technologii a także awarie, które mogą wywołać chaos w działaniu gospodarstwa i spowodować proces produkcji. Awarie mogą mieć skutki bezpośrednio wpływające na bezpieczeństwo integralności instytucji i rynku. Wyzwaniem staje się także wykluczenie cyfrowe wielu rolników oraz często niechęć do wdrażania nowych technologii (Xu i in., 2018).

Zapewnienie niezawodnej i szybkiej łączności jest kluczowe dla skutecznego przetwarzania i przesyłania danych wykorzystywanych w systemach sztucznej inteligencji, zwłaszcza takich, które działają w czasie rzeczywistym. Oprócz kamer rejestrujących obraz, system wymaga również specjalistycznego sprzętu do przetwarzania danych wizualnych oraz uruchamiania algorytmów analitycznych. Urządzenia te muszą być wydajne, odporne na uszkodzenia oraz dostosowane do warunków panujących w gospodarstwie m.in.: zmienne temperatury, różna wilgotność, kurz czy możliwość kontaktu ze zwierzętami.

Niezbędnym elementem jest również odpowiednia infrastruktura techniczna umożliwiająca stabilny montaż kamer, ich zabezpieczenie oraz ochronę pozostałych podzespołów systemu przed czynnikami środowiskowymi. Obejmuje to m.in. specjalne obudowy, konstrukcje montażowe, przewody odporne na warunki atmosferyczne oraz systemy zasilania awaryjnego (Mahato, Nethirajan, 2025). Według Department for Science, Innovation and Technology (2025) konieczne są dalsze badania nad zwiększaniem możliwości zastosowania technologii opartych na wykorzystaniu systemów AI w zmiennych warunkach środowiskowych oraz integracją z innymi technologiami rolniczymi.

Podsumowanie

Odpowiedzialne wykorzystanie zasobów sztucznej inteligencji w celu realizacji zrównoważonego rolnictwa ma kluczowe znaczenie dla przyszłości

produkcji żywności. Wdrożenie systemów AI w rolnictwie pozwala nie tylko na automatyzację i optymalizację procesów produkcyjnych, ale również na bardziej świadome gospodarowanie zasobami naturalnymi, takimi jak woda, gleba czy energia. Mimo wielu wyzwań związanych z implementacją systemów opartych na AI – w tym wysokich kosztów inwestycyjnych, wymagań infrastrukturalnych, skomplikowanych procesów integracji z istniejącymi technologiami oraz ryzyka wykluczenia technologicznego części producentów – potencjał aplikacyjny sztucznej inteligencji w rolnictwie dynamicznie rośnie.

Odpowiednio zaprojektowane i regulowane systemy AI mogą stać się kluczowym elementem w budowaniu bardziej efektywnego i zrównoważonego rolnictwa. Przykłady ich zastosowania obejmują m.in. monitorowanie stanu zdrowia roślin i zwierząt w czasie rzeczywistym, precyzyjne prognozowanie plonów, optymalizację zużycia nawozów i pestycydów oraz zarządzanie nawadnianiem w oparciu o dane meteorologiczne. Wdrożenie takich systemów pozwala nie tylko zwiększyć wydajność gospodarstw, ale również ograniczyć negatywny wpływ produkcji rolniczej na środowisko, wspierając jednocześnie realizację celów zrównoważonego rozwoju.

Literatura

1. Aliyu, A. A., Liu, J. (2023). Blockchain-Based Smart Farm Security Framework for the Internet of Things. *Sensors*, 23(18), 7992. <https://doi.org/10.3390/s23187992>
2. Amara, J., Bouaziz, B., Algergawy, A. (2017). A deep learning-based approach for banana leaf diseases classification. W: Mitschang B. (red.), *Datenbanksysteme für Business, Technologie und Web (BTW 2017)* (s. 79-88). LNI.
3. Department for Science, Innovation and Technology. (2025). *International AI Safety Report: First Key Update*. DSIT 2025/033.
4. Dhaliwal, Y., Bi, H., Neethirajan, S. (2025). Bimodal Data Analysis for Early Detection of Lameness in Dairy Cows Using Artificial Intelligence. *Journal of Agriculture and Food Research*, 21, 101832. <https://doi.org/10.1016/j.jafr.2025.101837>
5. Gołębiowska, A., Such-Pyrgiel, M. K., Prokopowicz, D. (2022). The post-pandemic reality and the security of information technologies ICT, Big Data,

- Industry 4.0, social media portals and the Internet. *Journal of Modern Science*, 49(2), 10-43. <https://doi.org/10.13166/jms/156912>
6. Grobelnik, M., Perset, K., Russell, S. (2024). *What is AI? Can you make a clear distinction between AI and non-AI systems?* OECD. AI Policy Observatory.
7. Kamilaris, A., Kartakoullis, A., Prenafeta-Boldú, F. X. (2017). A review on the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture*, 143, 23-37. <https://doi.org/10.1016/j.compag.2017.09.037>
8. Kamilaris, A., Prenafeta-Boldú, F. X. (2018a). A review of the use of convolutional neural networks in agriculture. *The Journal of Agricultural Science*, 156(3), 312-322. <https://doi.org/10.1017/S0021859618000436>
9. Kamilaris, A., Prenafeta-Boldú, F. X. (2018b). Deep learning in agriculture: a survey. *Computers and Electronics in Agriculture*, 147, 70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
10. Klusek, T., Łukasiewicz, K., Mrówczyńska-Kamińska, A., Pietrzak, P., Sobczak-Malitka, W. (2023). *Zrównoważony rozwój a funkcjonowanie wybranych sektorów gospodarki*. Oficyna Wydawnicza ASPRA-JR.
11. Kostina-Bednarz, M., Płonka, J., Barchanska, H. (2023). Allelopathy as a source of bioherbicides: challenges and prospects for sustainable agriculture. *Review of Environmental Science and Biotechnology*, 22, 471-504. <https://doi.org/10.1007/s11157-023-09656-1>
12. Kwasek, A., Maciaszczyk, M., Kocot, M., Rzepka, A., Kocot, D., Gasiński, H., Prokopowicz, D. (2023). Energy Saving Practices in the IT Area as a Factor of Sustainable Development of the Organization: A Case Study of Poland. *Energies*, 16(4), 1942. <https://doi.org/10.3390/en16041942>
13. Mahato, S., Neethirajan, S. (2025). Integrating Artificial Intelligence in dairy farm management – biometric facial recognition for cows. *Information Processing in Agriculture* 12(3), 312-325. <https://doi.org/10.1016/j.inpa.2024.10.001>
14. Neethirajan, S. (2023). SOLARIA-SensOr-driven resilient and adaptive monitoring of farm animals. *Agriculture*, 13(2), 436. <https://doi.org/10.3390/agriculture13020436>
15. Parivendan, S. C., Sailunaz, K., Neethirajan, S. (2025). Socializing AI: Integrating Social Network Analysis and Deep Learning for Precision Dairy Cow Monitoring – A Critical Review. *Animals*, 15(13), 1835. <https://doi.org/10.3390/ani15131835>

16. Prokopowicz, D. (2025). Sztuczna inteligencja i przemysł 4.0 w rolnictwie przyjaznym dla klimatu i odbudowie ekosystemów, ResearchGate, manuskrypt artykułu, preprint. <https://doi.org/10.13140/RG.2.2.30817.57447>
17. Różanowski, K. (2007). Sztuczna inteligencja: rozwój, szanse i zagrożenia. *Zeszyty Naukowe: Warszawska Wyższa Szkoła Informatyki*, 2, 109-135.
18. Sanyaolu, M., Sadowski, A. (2024). The Role of Precision Agriculture Technologies in Enhancing Sustainable Agriculture. *Sustainability*, 16(15), 6668. <https://doi.org/10.3390/su16156668>
19. Shah, M., Naik, N., Somani, B. K., Hameed, B. Z. (2020). Artificial intelligence (AI) in urology – current use and future directions: An iTRUE study. *Turkish Journal of Urology*, 46(1), 27. <https://doi.org/10.5152/tud.2020.20117>
20. Sztandarski, P., Marchewka, J., Jaszczyk, A., Solka, M., Michnowska, H., Pogorzelski, G., Gotxi, J. R., Damaziak, K., Wójcik, W., Siwiec, D., Seidawi, A., Horbańczuk, J. O. (2025). Scientific literature on AI technologies to enhance animal welfare, health and productivity. *Animal Science Papers and Reports*, 42(2), 11-132. <https://doi.org/10.2478/aspr-2025-0009>
21. Thornhill, S., Vargyas, E., Fitzgerald, T., Chisholm, N. (2016). Household food security and biofuel feedstock production in rural Mozambique and Tanzania. *Food Security*, 8, 953-971. <https://doi.org/10.1007/s12571-016-0603-9>
22. Tian, Z., Wang, J-W., Li, J., Han, B. (2021). Designing future crops: challenges and strategies for sustainable agriculture. *The Plant Journal*, 105(5), 1165-1178. <https://doi.org/10.1111/tpj.15107>
23. Toorajipour, R., Sohrabpour, V., Nazarpour, A., Oghazi, P., Fischl, M. (2021). Artificial Intelligence in Supply Chain Management: A Systematic Literature Review. *Journal of Business Research*, 122, 502-517. <https://doi.org/10.1016/j.jbusres.2020.09.009>
24. Xu, L.D., Xu, E. L., Li, L. (2018). Industry 4.0: State of the art and future trends. *International Journal of Production Research*, 56(8), 2941-2962. <https://doi.org/10.1080/00207543.2018.1444806>

**mgr inż. Barbara Jantos¹, mgr inż. Michał Wierzbicki²,
dr hab. inż. Michał Tomaszewski³**

Politechnika Opolska

APPLICATIONS AND LIMITATIONS OF ARTIFICIAL INTELLIGENCE METHODS IN PERSONALIZED REHABILITATION THERAPY

ZASTOSOWANIA I OGRANICZENIA METOD SZTUCZNEJ INTELIGENCJI W SPERSONALIZOWANEJ TERAPII REHABILITACYJNEJ

Abstract

This chapter aims to provide a literature review on the applications of artificial intelligence (AI) in personalized rehabilitation, covering the full therapeutic process from diagnostics and planning to monitoring and therapy support. A systematic review of the literature was conducted, focusing on six key domains: patient diagnostics and clinical assessment, personalization of rehabilitation plans, monitoring and support of therapies, virtual and robotic rehabilitation, predictive models for estimating recovery trajectories, and AI support for physicians and therapists. The analysis indicates that AI can improve diagnostic precision, predictive accuracy, and dynamic adaptation of rehabilitation programs to individual patient needs. At the same time,

¹ <https://orcid.org/0009-0001-9557-6787>, e-mail: b.jantos@student.po.edu.pl

² <https://orcid.org/0009-0006-5167-0866>

³ <https://orcid.org/0000-0001-6672-3971>

Jantos, B., Wierzbicki, M., Tomaszewski, M. (2026). Applications and limitations of artificial intelligence methods in personalized rehabilitation therapy. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 54-74). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_4

the chapter highlights significant limitations, including high implementation costs, lack of standardized protocols, data privacy challenges, and the potential exclusion of underrepresented patient groups. Identifying these limitations provides a foundation for further research and the development of strategies to enable more effective, safe, and equitable integration of AI into clinical personalized rehabilitation.

Keywords: artificial intelligence, healthcare informatics, personalized rehabilitation, AI-assisted therapy

Streszczenie

Celem rozdziału jest przegląd literatury dotyczącej zastosowań sztucznej inteligencji (AI) w spersonalizowanej rehabilitacji, obejmującej wszystkie etapy procesu terapeutycznego – od diagnozy, przez planowanie i monitorowanie, aż po wspieranie terapii. Przeprowadzono systematyczny przegląd literatury naukowej koncentrującej się na sześciu kluczowych obszarach: diagnostyce i ocenie stanu pacjenta, personalizacji planów rehabilitacyjnych, monitorowaniu i wspieraniu terapii, rehabilitacji wirtualnej i robotycznej, modelach predykcyjnych prognozujących tempo powrotu do zdrowia oraz wsparciu dla lekarzy i terapeutów. Analiza literatury wskazuje, że AI może zwiększać precyzję diagnozy, poprawiać trafność prognoz oraz umożliwiać dynamiczne dostosowanie terapii do indywidualnych potrzeb pacjentów. Jednocześnie artykuł podkreśla istotne ograniczenia, takie jak wysokie koszty wdrożeń, brak standaryzacji protokołów, problemy z ochroną danych oraz ryzyko wykluczenia niektórych grup pacjentów. Wskazanie tych ograniczeń umożliwia wytyczenie kierunków dalszych badań i poszukiwania rozwiązań, które pozwolą na skuteczniejszą i bezpieczniejszą integrację AI w procesie spersonalizowanej rehabilitacji klinicznej.

Słowa kluczowe: sztuczna inteligencja, informatyka medyczna, spersonalizowana rehabilitacja, terapia wspierana AI

Introduction

The integration of artificial intelligence (AI) into healthcare has initiated a paradigm shift toward more individualized, data-driven models of diagnosis, treatment, and rehabilitation. Personalized rehabilitation therapy, which aims to tailor interventions to the unique physiological, psychological, and social circumstances of each patient, stands at the intersection of technological innovation and clinical practice. In this context, AI emerges not merely as a supplementary tool but as a transformative enabler, supporting clinicians

in diagnostics, optimizing rehabilitation strategies, monitoring therapeutic processes, and enabling advanced modalities such as virtual and robotic rehabilitation.

Recent advancements have demonstrated the potential of AI-driven models to enhance diagnostic precision, improve outcome prediction, and dynamically adapt rehabilitation pathways. However, despite these promising developments, the adoption of AI in personalized rehabilitation remains constrained by a variety of limitations, understood here broadly as encompassing both methodological shortcomings of current research and practical barriers to clinical implementation. These include technological, economic, and ethical constraints, such as the high cost of implementation, the absence of standardized therapeutic protocols, data privacy concerns, and the risk of underrepresentation of certain patient groups in AI training datasets, which may perpetuate inequalities in healthcare access and quality.

The aim of this chapter is to provide a comprehensive literature-based review of AI applications in personalized rehabilitation, spanning the continuum from patient diagnostics to recovery monitoring and therapeutic support. Specifically, it examines six key domains: (1) AI in patient diagnostics and clinical assessment, (2) AI-driven personalization of rehabilitation strategies, (3) AI in monitoring and enhancing therapeutic processes, (4) AI-enabled virtual and robotic rehabilitation, (5) predictive AI models for forecasting recovery trajectories, and (6) AI support for physicians and therapists. Through this structured analysis, the chapter seeks to identify existing gaps in the field, evaluate the applicability of current approaches, and outline directions for future development.

The contribution of this work is interdisciplinary. From a computer science perspective, it synthesizes methods for personalization within AI systems. For the medical and health sciences, it highlights evidence of both current and potential improvements in rehabilitation outcomes driven by AI integration. From an economic standpoint, it considers issues of cost-effectiveness, scalability, and the allocation of healthcare resources. Furthermore, it addresses ethical and cultural dimensions, such as the exclusion of underrepresented groups in AI training datasets, the digital divide affecting older or socioeconomically disadvantaged patients, and the cultural acceptance of AI-driven interventions. By weaving together these perspectives, this review offers a holistic understanding of both

the opportunities and limitations of AI in advancing personalized rehabilitation therapy.

AI in patient diagnostics and clinical assessment

Personalized diagnosis and treatment have gained significant importance in recent years, thanks to the rapid development of AI. New technologies have allowed us to analyze vast amounts of data and synthesize knowledge from those sources. AI has infiltrated a variety of domains, from the automotive industry to advertisements to healthcare. For years, healthcare workers have been overworked (Duong, Vogel, 2023), which directly impacts the efficiency of this sector as a whole. Implementing AI into the healthcare workflow can ease the workload and improve the inner workings of the medical sector (Wierzbicki et al., 2024).

AI provides an opportunity to perform deeper and broader analysis of medical data than traditional clinical approaches, as it can simultaneously process information from multiple sources, such as imaging, biological signals, genomics, and electronic health records. Oftentimes, medical workers have to rely on limited results since it is time-consuming to deeply analyze all the information in the patients' documentation and extract patterns and correlations that accurately describe patients' state (Miotto et al., 2018; Esteva et al., 2019).

AI has outperformed human experts in detecting pathologies from medical images such as X-rays, MRI, and CT, with notable success in breast cancer and chest X-ray analysis (Khalifa, Albadawy, 2024; Huhulea et al., 2025). Radiomics enables extraction of high-dimensional features to uncover subtle patterns, supporting diagnosis, disease monitoring, and treatment evaluation. Beyond imaging, deep learning improves analysis of biological signals (e.g., arrhythmia in ECG (Hannun et al., 2019), epileptic seizures in EEG (Craik et al., 2019)) and sensor-based systems allow automatic classification of motor dysfunction, offering clinicians objective and reproducible measures for therapy planning (Attoh-Mensah et al., 2025). Increasingly, AI also predicts disease relapse, hospital readmission, and postoperative complications (Goldstein et al., 2017).

AI-driven personalization of rehabilitation strategies

The rehabilitation process is inherently complex, and multidisciplinary. Consequently, optimizing it remains a considerable challenge. One promising approach is to place the patient at the center of treatment and rehabilitation, as this strategy holds potential for improved outcomes through individually tailored interventions. Such personalization may range from setting therapeutic goals collaboratively with the patient, adapting practices to specific needs, and ultimately creating fully individualized therapy plans that account for personal limitations and preferences (Boltaboyeva et al., 2025).

Using specialist expertise, patient records, and diagnostic data processed by AI, personalized therapy plans can be delivered. In a study by Yun & Choi (2019), a randomized trial comparing conventional therapy with AI-augmented mobile rehabilitation for knee osteoarthritis showed significant improvements in quality of life and physical activity, though the lack of full blinding warrants cautious interpretation.

A critical component of any therapy plan concerns the setting of appropriate goals and the calibration of exercise difficulty. AI techniques can provide valuable assistance in this regard. For instance, Thiengwittayaporn et al. (2021) describe the development of a predictive model for movement difficulty. In this study, subjects were required to complete several practice rounds with feedback before the model could accurately predict the expected difficulty level.

When considering personalized therapy, it is also essential to address the role of large language models (LLMs). In a study by Mykhalko et al. (2025), the authors prompted ChatGPT-4o to generate rehabilitation plans for 50 clinical cases. After expert evaluation, the majority of the AI-generated plans were rated as clinically appropriate, safe, and suitable for use. Nevertheless, the authors noted that these plans still required refinement and should always undergo professional review before implementation.

Personalization can further extend to supporting patients through tailored interactions that reinforce desired behaviors (MohammadNamdar et al., 2025). Such strategies not only improve patient engagement but also reduce dropout rates. By facilitating adherence to rehabilitation programs, AI-driven approaches can enhance the overall effectiveness of therapy.

Decision-support systems and AI-powered rehabilitation tools assist in designing treatment plans, predicting outcomes, and tailoring therapeutic components to patient-specific characteristics (Alshami et al., 2025). As a result, outcomes are improved, patient satisfaction increases, and clinicians receive additional support in their work. All those factors contribute to the rehabilitation optimization, though further research and validation remain necessary.

AI in personalized therapy holds promise for improving patient adherence, providing more effective interventions, and alleviating the workload of healthcare professionals (Attoh-Mensah et al., 2025). Beyond plan generation, AI systems can support continuous monitoring and adaptive adjustment of therapy intensity. Nonetheless, widespread adoption requires shifts in clinical practice, sustained funding, and close collaboration among specialists. Furthermore, issues surrounding responsibility for therapeutic failures remain to be addressed.

AI in monitoring and enhancing therapeutic processes

Advances in therapeutic interventions allow assessment of how well therapy is tailored to patients and whether outcomes are achieved. AI-driven monitoring – implemented through platforms, wearables, sensors, or chatbot interfaces (Aziz et al., 2024) – automates data collection, enables real-time analysis, and issues alerts when progress stalls, extending telerehabilitation and making home-based care more effective.

An illustrative example of sensor integration in rehabilitation is the use of physiographs designed for gait assessment and monitoring in Parkinson's disease (Jiao, 2025). Based on the acquired data, the proposed system supports clinicians through decision support mechanisms. However, its evaluation was limited to only 10 participants. Similarly, Sumner et al. (2023) described an IoT-based smart sensing system for gait monitoring. Despite promising results obtained from 14 volunteers, the study highlighted the necessity of addressing sensor limitations in future work. Issues related to small sample sizes were also emphasized in a study by Ileşan et al. (2022), where an AI-driven system was developed for upper-limb rehabilitation. Although the findings were encouraging, the limited cohort prevents clinical deployment without further

large-scale validation. Notably, the authors also addressed another critical concern in such systems – ensuring the security of transmitted data.

Data privacy and security are among the most pressing challenges for AI-enhanced rehabilitation systems (Laganà et al., 2025). Wearables, monitoring platforms, and feedback systems process and transmit highly sensitive information that must be adequately protected. Without clear regulations and robust safeguards, user trust in these technologies will remain limited.

AI-powered sensing technologies offer the capability to detect subtle abnormalities and provide rapid responses to support patients. Nevertheless, as illustrated in a study by Monge et al. (2023), AI-driven feedback must be understandable, reliable, accurate, quantitative, and context-specific in order to be clinically useful. Without such qualities, the benefits of personalization may be lost, and patient adherence to therapy compromised.

Beyond the complexity of feedback mechanisms, it is also important to recognize the inherent limitations of current sensor technologies. Not all therapeutic elements can be accurately measured – for instance, the correctness of exercise execution remains difficult to capture and evaluate reliably (Abery et al., 2025). Inaccurately gathered data may, in turn, lead to poorly trained models and potential errors in therapeutic recommendations.

Biofeedback and telemedicine systems rely heavily on multidisciplinary collaboration. Effective solutions require close cooperation between AI researchers and medical professionals to ensure a comprehensive understanding of therapeutic principles, signal interpretation, and patient needs. While wearables and sensors can substantially enhance rehabilitation systems, they may also introduce practical challenges, such as discomfort from prolonged use or the need for frequent updates (Mawson et al., 2016). Furthermore, isolated sensor data may not fully reflect the patient's overall condition. Hence, preserving the broader clinical and personal context is essential for AI-enhanced rehabilitation to be effective.

AI-enabled virtual and robotic rehabilitation

Virtual reality (VR) is a technology that enables the creation of computer-generated 3D environments in which the user can immerse themselves and interact using specialized devices, such as VR headsets or haptic gloves. In

contrast, augmented reality (AR) overlays digital elements onto the real world, enhancing the user's perception with additional visual, auditory, or tactile information. As noted in a study by Alshami et al. (2025), both technologies, when combined with AI, open new perspectives in rehabilitation, allowing for the creation of personalized therapeutic environments and the adaptation of treatment programs to individual patient needs. AI analyzes patient data, such as movement patterns, biomechanics, and physiological responses, enabling progress prediction and real-time optimization of therapy plans.

Rehabilitation robotics using machine learning (ML) algorithms allows precise adjustment of resistance, range of motion, and training intensity according to the patient's capabilities and limitations. AI-assisted exoskeletons are particularly useful in gait and lower limb rehabilitation, providing not only mechanical support but also intelligent adaptation to the patient's evolving clinical condition (Abery et al., 2025). Publication by Zhu et al. (2023) emphasizes that robot-assisted therapies improve functional outcomes, although evidence regarding long-term efficacy for lower limbs remains limited. Simultaneously, issues such as implementation costs and the lack of standardized protocols hinder broader adoption.

VR/AR in rehabilitation, supported by AI, allow the simulation of realistic therapeutic environments, increasing patient immersion and motivation. Applications include post-stroke rehabilitation, balance disorder therapy, and neurological rehabilitation. Systematic reviews (Mizna et al., 2025) indicate that VR can improve motor therapy outcomes; however, effectiveness depends on the quality of intervention personalization and the method of patient monitoring in home settings. AI-based therapeutic games (Cardone et al., 2025) are also important, adjusting difficulty levels according to the patient's current abilities, thereby supporting neuroplasticity and increasing engagement.

Despite growing evidence on the therapeutic value of VR, AR, and AI-assisted robotics in rehabilitation, their clinical adoption remains limited by high acquisition and maintenance costs and the continuous training required for staff (Devittori et al., 2024). The lack of standardized protocols and multicenter trials with sufficiently powered cohorts further constrains generalizability, as most findings stem from small, context-specific studies. Ethical and regulatory issues concerning data privacy and cybersecurity risks raise additional concerns, potentially undermining trust among patients and clinicians (Mizna

et al., 2025). Effective integration also depends on infrastructure investment and systematic personnel upskilling, as deficits in preparedness often relegate these technologies to experimental rather than routine use (Devittori et al., 2024). Finally, psychological and sociocultural barriers, including variable patient acceptance, risk of cybersickness, and lower digital literacy among older populations, limit equitable access and sustained engagement.

Predictive AI models for forecasting recovery trajectories

One of the most critical aspects of personalized treatment and rehabilitation is that one can tailor the program for the needs of the patient, but more importantly, one can assess progress on a case-by-case basis, providing a prognosis of the patient's state. The ability to predict how a patient's condition will evolve and how a patient will respond to the therapy over time proves to be the focal point of patient-centered healthcare. Personalized rehabilitation can be further enhanced by additional input from the AI model, which would predict the trajectory of recovery. The team in China conducted a study to predict recovery time in a cohort of over 13,000 patients (Xu et al., 2022). The authors utilized five ML methods, and in 7-day and 14-day recovery time predictions, the authors achieved over 90% accuracy. Similarly, AI proved to be significantly effective in cognitive rehabilitation therapy (Khalid et al., 2024). A variety of applications have been created and tested to elevate patients' mental state in the battle with dementia, neurological or developmental disorders, or neurodegenerative diseases, among many. For example, using an AI-driven application, users tend to become engaged in cognitive tasks.

Another important aspect of safe and effective rehabilitation is appropriate adjustment of intensity. Medical practitioners assess patients' performance at discrete intervals, often weeks apart. Such an approach is inherently at risk of missing crucial datapoints and fluctuations in performance. Real-time continuous monitoring prevents loss of information and provides a full picture of patients' conditions throughout the time period, while at the same time enhancing patients' safety (Khalid et al., 2024). The idea of continuous real-time monitoring is a beneficial practice in treating diabetes (Beck et al., 2017), where continuous glucose monitoring (CGM) has transformed disease management.

In rehabilitation, wearable sensors – much like glucose monitors in diabetes – provide instant access to patient data. Combined with robotic exoskeletons, they can adjust exercise resistance and, through continuous monitoring, detect abnormal vitals, movement, or pathologies (Attoh-Mensah et al., 2025). AI further integrates multimodal data to reveal hidden patterns and recovery bottlenecks, helping identify factors that delay progress.

In the case of post-COVID-19 rehabilitation, Xu et al. (2022) concluded that older age, comorbidities (such as diabetes and hypertension), and higher viral loads were associated with longer recovery durations. Campagnini et al. (2022) conducted a study on 278 post-stroke patients with the goal of developing ML models that predict the functional prognosis. While the models' outcomes are not clear-cut, the authors have managed to identify the most important factors in rehabilitation efficacy: trunk control, bedsores, and communication levels. Beyond clinical factors, Khalid et al. (2024) indicate that personal and behavioral factors also play a role in the recovery process. Missed therapy sessions, insufficient home exercise, or inadequate sleep can significantly delay recovery. Patients who stuck with the schedule and were engaged in rehabilitation obtained better results than those who weren't adhering to the rehabilitation program.

Psychological variables impact the rehabilitation process in a significant way (Mascanzoni et al., 2024). Self-esteem and emotional regulation were identified as leading factors that increase the quality of rehabilitation. Conversely, depression and anxiety were highlighted as leading negative factors hindering rehabilitation. These findings underline the importance of psychological support during the rehabilitation process and point towards a holistic approach in personalized rehabilitation, especially the incorporation of psychological care with the goal of improving overall well-being.

Rehabilitation can be a lengthy process, taking weeks, months, or even years, with the goal of improving comfort of life, maximizing functional abilities, or mitigating the effects of illnesses, injuries, or disabilities. Creating a well-adjusted long-term plan for each individual case is a key factor for long-term success. Clinicians need tools to perform a forecast of patients' performance and adjust the rehabilitation program accordingly.

Digital twin is a concept involving the creation of a data-rich replica of a patient, used for simulating and testing various rehabilitation strategies to

predict the patient's likely response and identify the most promising approach (Bruynseels et al., 2018). This tool enables long-term simulation of rehabilitation programs, the evaluation of multiple treatment variants, and ensures patient safety by operating entirely on multimodal patient data.

Another approach that utilizes AI to increase the effectiveness of long-term rehabilitation is survival analysis, which serves as a tool for explaining and understanding the relationship between patients' covariates and efficacy of the rehabilitation (Katzman et al., 2018). The authors introduce DeepSurv – “a Cox proportional hazards deep neural network and state-of-the-art survival method for modeling interactions between a patient's covariates and treatment effectiveness in order to provide personalized treatment recommendations”. The obtained results prove the model's ability to capture complex relationships and its long-term modeling capabilities. Among a number of experiments authors managed to obtain results comparable with state-of-the-art solutions or outperform them, which directly translates to better care for patients and prolonging their lives.

AI support for physicians and therapists

Shifting the perspective towards physical therapy specialists, it becomes evident that many are both aware of and expectant of the increasing role of AI in their professional practice (Aldhahi et al., 2025). They anticipate that AI will ease their workload, assist in task optimization, and a considerable proportion (47.9%) express enthusiasm for integrating AI into physical therapy. Nevertheless, despite this generally optimistic outlook, researchers highlight a notable gap in education: physical therapy professionals often lack adequate training in AI, including its potential applications and limitations. This knowledge gap is reflected in their limited trust towards AI-based solutions.

Building trust in AI is a complex and multifaceted challenge. As outlined in a study by Alonso et al. (2025), trust is influenced by several factors, such as:

- the function of AI (e.g. therapy plan recommendations, therapy monitoring);
- the accuracy, reliability, and robustness of outputs;
- the type of pathology under consideration;
- the treatment modality and its degree of explainability;

- the attitudes and predispositions of healthcare professionals;
- the way in which AI outputs are presented;
- the clinical context in which AI is applied.

Developing a comprehensive framework that addresses these factors would significantly increase healthcare professionals' readiness to adopt AI and thereby unlock its full potential in rehabilitation practice. This aligns with patient perspectives reported in a study by Foresman et al. (2025), where respondents underline that final treatment decisions should remain in human hands, given AI's current limitations in transparency and explainability. Patients also underscored the need for personalization in rehabilitation, noting the difficulty of applying a common model to individuals with highly specific needs. While AI can serve as a valuable support tool in rehabilitation, it should not be deployed without human oversight.

To effectively integrate medical specialists into AI workflows, it is important to educate them. Such efforts should begin at the curricular level, but also extend to collaborative testing of AI solutions with practitioners (Ayorinde et al., 2024). Involving clinicians in system development allows them to articulate desired functionalities and emulate professional expertise, while simultaneously gaining exposure to AI technologies. This co-development process helps with mutual learning and better alignment between technical design and clinical requirements. Lee et al. (2020) presented an AI system for stroke rehabilitation assessment developed in collaboration with therapists. During the design phase, clinicians initially struggled to interpret the technical terminology used to describe model features. This required AI specialists to adjust and rename the features to enhance clarity. It shows that even such small elements of the design process are being impacted, when working with end users, therefore it is worth including them from the very beginning of the process. After completing the system and testing it, therapists evaluated the decision support system as more useful, informative, and less effortful compared to traditional methods. However, the study's limitations included a small sample size and a relatively narrow focus on supporting a single decision-making task.

Beyond decision support, AI in rehabilitation holds promise for streamlining administrative processes, such as the creation and maintenance of medical records. By accelerating documentation, AI may help alleviate

time pressures and reduce dissatisfaction among professionals, leading to both improved record quality and better work-life balance (Omon et al., 2025). Reducing the administrative burden is often cited as one of the key advantages of implementing AI in healthcare. This, in turn, has significant economic implications, enhancing cost-effectiveness through more efficient resource allocation and supporting personalized rehabilitation. Nevertheless, despite long-term cost-saving potential (Cano-de-la-Cuerda et al., 2024), the initial financial investment required for AI in rehabilitation is substantial. It entails expensive hardware, ongoing system development, maintenance, and interdisciplinary collaboration. Moreover, these high entry costs may exacerbate inequalities in access, particularly across underfunded regions or minority populations, thereby risking the reinforcement of existing healthcare disparities.

Discussion

The analysis of current literature reveals that, despite substantial advances in the use of AI in personalized rehabilitation, a number of recurring and section-specific limitations constrain its practical implementation. To illustrate these overlaps and divergences, Figure 1 presents a circular diagram where identical colors mark limitations that are shared across multiple thematic domains, while unique issues are highlighted in distinct shades.

As indicated in light blue, data-related issues – such as quality, heterogeneity, and sensor accuracy – are consistently reported in diagnostics, personalization, and monitoring processes. Similarly, green nodes highlight recurring concerns regarding data privacy and ethical accountability, a theme particularly pronounced in diagnostics, personalization, monitoring, and robotic rehabilitation. Methodological limitations, including insufficient validation and interpretability of AI models, are clustered in light pink, illustrating a common research gap across personalization, monitoring, and predictive modeling.




Figure 1. Shared and section-specific limitations of AI applications in personalized rehabilitation, grouped by thematic categories

Source: authors' own work.

Barriers linked to professional readiness, coded in lime, underscore the necessity of clinician training and engagement in multiple domains, whereas orange nodes emphasize the financial and infrastructural burdens that affect primarily robotic rehabilitation and clinical AI support. Finally, violet nodes represent patient-related challenges, including acceptance, adherence, and comfort, which are crucial for the successful integration of AI-driven solutions in real-world settings.

By contrast, several barriers remain domain-specific, highlighted in distinct colors such as red (overdiagnosis, false positives, and system integration in diagnostics), cyan (temporality of diseases and biomedical domain complexity in predictive models), and gold (transparency, explainability, and inequitable

access in AI support). These constraints reflect the unique methodological and contextual challenges faced by each subfield.

Overall, the diagram underscores that while some limitations are ubiquitous across domains – particularly those concerning data quality, ethics, and clinician training – others are tightly bound to specific applications. Among the critical challenges that hinder clinical deployment are:

- 1) lack of standardized, well-maintained datasets,
- 2) limited explainability and interpretability of the models and AI solutions,
- 3) limited validation from healthcare practitioners.

This dual perspective highlights the need for both system-wide strategies to address recurring barriers and domain-specific solutions to overcome unique challenges, thereby paving the way for more effective integration of AI into personalized rehabilitation therapy.

Furthermore, literature review highlighted important aspect of AI within personalized rehabilitation – lack of holistic end-to-end study that assess AI-supported diagnostic process, adaptive personalization of rehabilitation programs and long-term monitoring within a unified rehabilitation pipeline. Oftentimes, evaluation of AI solutions is conducted in the vacuum, without consideration of the process as a whole and external factors. Such approach limits assessment of real clinical utility and understanding of environmental and systematic needs for AI.

Conclusions

AI holds considerable promise for advancing personalized rehabilitation, given rise to patient-centric approaches. However, current analysis indicates that successful implementation of AI-driven solutions is dependent on overcoming limited availability of high-quality datasets, lack of explainability and interpretability of models as well as insubstantial involvement of the medical workforce in the process. All those factors are amplified by financial, methodological, ethical, and accessibility barriers which hinders widespread clinical adoption. Progress in these areas will likely require standardized evaluation protocols, explainable AI frameworks, and closer integration of clinician expertise into model design and validation workflows. In addition,

targeted training for healthcare professionals and interoperable technical infrastructure are necessary to support safe and effective deployment. Addressing these limitations is essential for translating technological potential into sustainable improvements in patient care.

Future works

The present discussion is based on a qualitative literature analysis focused on identifying the principal thematic areas, opportunities, and limitations of AI applications in personalized rehabilitation. The conclusions therefore reflect a structured synthesis of reported findings rather than a quantitative analysis of performance metrics or outcome measures. Future study could focus on a quantitatively oriented approach, including extraction and comparison of reported numerical indicators. This would allow a more evidence-based assessment of both the practical potential and the measurable limitations of AI-driven rehabilitation methods.

References

1. Abery, P., Canetti, E., Hing, W. (2025). The role of lower limb exoskeletons in rehabilitation: a scoping review. *Physical Therapy Reviews*, 30(2), 118-136. <https://doi.org/10.1080/10833196.2025.2465937>
2. Aldhahi, M. I., Alorainy, A. I., Abuzaid, M. M., Gareeballah, A., Alsubaie, N. F., Alshamary, A. S., Hamd, Z. Y. (2025). Adoption of artificial intelligence in rehabilitation: perceptions, knowledge, and challenges among healthcare providers. *Healthcare*, 13(4), 350. <https://doi.org/10.3390/healthcare13040350>
3. Alonso, M., Astobiza, A. M., Ortega Lozano, R. (2025). AI-mediated healthcare and trust. A trust-construct and trust-factor framework for empirical research. *Artificial Intelligence Review*, 58(11), 337. <https://doi.org/10.1007/s10462-025-11306-7>
4. Alshami, A., Nashwan, A., AlDardour, A., Qusini, A. (2025). Artificial intelligence in rehabilitation: a narrative review on advancing patient care. *Rehabilitaci3n*, 59(2), 100911. <https://doi.org/10.1016/j.rh.2025.100911>
5. Attoh-Mensah, E., Boujut, A., Desmons, M., Perrochon, A. (2025). Artificial intelligence in personalized rehabilitation: current applications and a SWOT

- analysis. *Frontiers in Digital Health*, 7, 1606088. <https://doi.org/10.3389/fdgth.2025.1606088>
6. Ayorinde, A., Mensah, D. O., Walsh, J., Ghosh, I., Ibrahim, S. A., Hogg, J., Peek, N., Griffiths, F. (2024). Health care professionals' experience of using AI: systematic review with narrative synthesis. *Journal of Medical Internet Research*, 26, e55766. <https://doi.org/10.2196/55766>
 7. Aziz, R., Jawed, F., Khan, S.A., Sundus, H. (2024). Wearable IoT devices in rehabilitation: enabling personalized precision medicine. In: Khang, A. (ed.), *Medical Robotics and AI-Assisted Diagnostics for a High-Tech Healthcare Industry* (p. 281-308). IGI Global. <https://doi.org/10.4018/979-8-3693-2105-8.ch018>
 8. Beck, R. W., Riddlesworth, T., Ruedy, K., Ahmann, A., Bergenstal, R., Haller, S., Kollman, C., Kruger, D., McGill, J. B., Polonsky, W., Toschi, E., Wolpert, H., Price, D. (2017). Effect of continuous glucose monitoring on glyce-mic control in adults with type 1 diabetes using insulin injections: the dia-mond randomized clinical trial. *JAMA*, 317(4), 371. <https://doi.org/10.1001/jama.2016.19975>
 9. Boltaboyeva, A., Baigarayeva, Z., Imanbek, B., Ozhikenov, K., Getahun, A. J., Aidarova, T., Karymsakova, N. (2025). A review of innovative medical re-habilitation systems with scalable AI-assisted platforms for sensor-based re-cove-ry monitoring. *Applied Sciences*, 15(12), 6840. <https://doi.org/10.3390/app15126840>
 10. Bruynseels, K., Santoni De Sio, F., Van Den Hoven, J. (2018). Digital twins in health care: ethical implications of an emerging engineering paradigm. *Frontiers in Genetics*, 9, 31. <https://doi.org/10.3389/fgene.2018.00031>
 11. Campagnini, S., Liuzzi, P., Mannini, A., Basagni, B., Macchi, C., Carrozza, M. C., Cecchi, F. (2022). Cross-validation of predictive models for functional recovery after post-stroke rehabilitation. *Journal of NeuroEngineering and Rehabilitation*, 19(1), 96. <https://doi.org/10.1186/s12984-022-01075-7>
 12. Cano-de-la-Cuerda, R., Blázquez-Fernández, A., Marcos-Antón, S., Sán-chez-Herrera-Baeza, P., Fernández-González, P., Collado-Vázquez, S., Jiménez-Antona, C., Laguarda-Val, S. (2024). Economic cost of rehabilitation with robotic and virtual reality systems in people with neurological disorders: a systematic review. *Journal of Clinical Medicine*, 13(6), 1531. <https://doi.org/10.3390/jcm13061531>

13. Cardone, D., Perpetuini, D., Di Nicola, M., Merla, A., Morone, G., Ciancarelli, I., Moretti, A., Gimigliano, F., Cichelli, A., De Flaviis, F., Martino Cinnera, A., Paolucci, T. (2025). Robot-assisted upper limb therapy for personalized rehabilitation in children with cerebral palsy: a systematic review. *Frontiers in Neurology*, 15, 1499249. <https://doi.org/10.3389/fneur.2024.1499249>
14. Craik, A., He, Y., Contreras-Vidal, J. L. (2019). Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of Neural Engineering*, 16(3), 031001. <https://doi.org/10.1088/1741-2552/ab0ab5>
15. Devittori, G., Dinacci, D., Romiti, D., Califfi, A., Petrillo, C., Rossi, P., Ranzani, R., Gassert, R., Lambercy, O. (2024). Unsupervised robot-assisted rehabilitation after stroke: feasibility, effect on therapy dose, and user experience. *Journal of NeuroEngineering and Rehabilitation*, 21(1), 52. <https://doi.org/10.1186/s12984-024-01347-4>
16. Duong, D., Vogel, L. (2023). Overworked health workers are “past the point of exhaustion”. *Canadian Medical Association Journal*, 195(8), E309-E310. <https://doi.org/10.1503/cmaj.1096042>
17. Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., Cui, C., Corrado, G., Thrun, S., Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25(1), 24-29. <https://doi.org/10.1038/s41591-018-0316-z>
18. Foresman, G., Biro, J., Tran, A., MacRae, K., Kazi, S., Schubel, L., Visconti, A., Gallagher, W., Smith, K. M., Giardina, T., Haskell, H., Miller, K. (2025). Patient perspectives on artificial intelligence in health care: focus group study for diagnostic communication and tool implementation. *Journal of Participatory Medicine*, 17, e69564-e69564. <https://doi.org/10.2196/69564>
19. Goldstein, B. A., Navar, A. M., Pencina, M. J., Ioannidis, J. P. A. (2017). Opportunities and challenges in developing risk prediction models with electronic health records data: a systematic review. *Journal of the American Medical Informatics Association*, 24(1), 198-208. <https://doi.org/10.1093/jamia/ocw042>
20. Hannun, A. Y., Rajpurkar, P., Haghpanahi, M., Tison, G. H., Bourn, C., Turakhia, M. P., Ng, A. Y. (2019). Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine*, 25(1), 65-69. <https://doi.org/10.1038/s41591-018-0268-3>
21. Huhulea, E. N., Huang, L., Eng, S., Sumawi, B., Huang, A., Aifuwa, E., Hirani, R., Tiwari, R. K., Etienne, M. (2025). Artificial intelligence advancements

- in oncology: a review of current trends and future directions. *Biomedicines*, 13(4), 951. <https://doi.org/10.3390/biomedicines13040951>
22. Ileșan, R. R., Cordoș, C.-G., Mihăilă, L.-I., Fleșar, R., Popescu, A.-S., Perju-Dumbravă, L., Faragó, P. (2022). Proof of concept in artificial-intelligence-based wearable gait monitoring for Parkinson's disease management optimization. *Biosensors*, 12(4), 189. <https://doi.org/10.3390/bios12040189>
23. Jiao, D. (2025). AI-enhanced digital therapeutics for cognitive impairment: integrating mobile applications, virtual reality, and wearable devices. *Discover Artificial Intelligence*, 5(1), 69. <https://doi.org/10.1007/s44163-025-00325-6>
24. Katzman, J. L., Shaham, U., Cloninger, A., Bates, J., Jiang, T., Kluger, Y. (2018). DeepSurv: personalized treatment recommender system using a Cox proportional hazards deep neural network. *BMC Medical Research Methodology*, 18(1), 24. <https://doi.org/10.1186/s12874-018-0482-1>
25. Khalid, U. B., Naeem, M., Stasolla, F., Syed, M. H., Abbas, M., Coronato, A. (2024). Impact of AI-powered solutions in rehabilitation process: recent improvements and future trends. *International Journal of General Medicine*, 17, 943-969. <https://doi.org/10.2147/IJGM.S453903>
26. Khalifa, M., Albadaawy, M. (2024). AI in diagnostic imaging: revolutionising accuracy and efficiency. *Computer Methods and Programs in Biomedicine Update*, 5, 100146. <https://doi.org/10.1016/j.cmpbup.2024.100146>
27. Laganà, F., Pellicanò, D., Arruzzo, M., Praticò, D., Pullano, S. A., Fiorillo, A. S. (2025). Fem-based modelling and ai-enhanced monitoring system for upper limb rehabilitation. *Electronics*, 14(11), 2268. <https://doi.org/10.3390/electronics14112268>
28. Lee, M. H., Siewiorek, D. P., Smailagic, A., Bernardino, A., Bermúdez i Badia, S. (2020). Co-design and evaluation of an intelligent decision support system for stroke rehabilitation assessment. *Proceedings of the ACM on Human-Computer Interaction*, 4(CSCW2), 1-27. <https://doi.org/10.1145/3415227>
29. MohammadNamdar, M., Lowery Wilson, M., Murtonen, K.-P., Aartolahti, E., Oduor, M., Korniloff, K. (2025). How AI-based digital rehabilitation improves end-user adherence: rapid review. *JMIR Rehabilitation and Assistive Technologies*, 12, e69763-e69763. <https://doi.org/10.2196/69763>
30. Mascanzoni, M., Luciani, A., Tamburella, F., Iosa, M., Lena, E., Di Fonzo, S., Pisani, V., Di Lucente, M. C., Caretti, V., Sideli, L., Cuzzocrea, G., Scivoletto, G. (2024). The role of psychological variables in predicting rehabilitation

- outcomes after spinal cord injury: an artificial neural networks study. *Journal of Clinical Medicine*, 13(23), 7114. <https://doi.org/10.3390/jcm13237114>
31. Mawson, S., Nasr, N., Parker, J., Davies, R., Zheng, H., Mountain, G. (2016). A personalized self-management rehabilitation system with an intelligent shoe for stroke survivors: a realist evaluation. *JMIR Rehabilitation and Assistive Technologies*, 3(1), e1. <https://doi.org/10.2196/rehab.5079>
32. Miotto, R., Wang, F., Wang, S., Jiang, X., Dudley, J. T. (2018). Deep learning for healthcare: review, opportunities and challenges. *Briefings in Bioinformatics*, 19(6), 1236-1246. <https://doi.org/10.1093/bib/bbx044>
33. Mizna, S., Arora, S., Saluja, P., Das, G., Alanesi, W. A. (2025). An analytic research and review of the literature on practice of artificial intelligence in healthcare. *European Journal of Medical Research*, 30(1), 382. <https://doi.org/10.1186/s40001-025-02603-6>
34. Monge, J., Ribeiro, G., Raimundo, A., Postolache, O., Santos, J. (2023). AI-based smart sensing and AR for gait rehabilitation assessment. *Information*, 14(7), 355. <https://doi.org/10.3390/info14070355>
35. Mykhalko, Y., Dydytska, S., Balatska, L., Filak, F., Rubtsova, Y. (2025). AI-driven rehabilitation: evaluation of ChatGPT-4o for generating personalized physical rehabilitation plans in comorbid patients. *Wiadomości Lekarskie*, 4, 753-759. <https://doi.org/10.36740/WLek/203850>
36. Omon, K., Sasaki, T., Koshiro, R., Fuchigami, T., Hamashima, M. (2025). Effects of introducing generative AI in rehabilitation clinical documentation. *Cureus*, 17(3), e81313. <https://doi.org/10.7759/cureus.81313>
37. Sumner, J., Lim, H. W., Chong, L. S., Bunde, A., Mukhopadhyay, A., Kayambu, G. (2023). Artificial intelligence in physical rehabilitation: a systematic review. *Artificial Intelligence in Medicine*, 146, 102693. <https://doi.org/10.1016/j.artmed.2023.102693>
38. Thiengwittayaporn, S., Wattanapreechanon, P., Sakon, P., Peethong, A., Ratisoonporn, N., Charoenphandhu, N., Charoensiriwath, S. (2021). Development of a mobile application to improve exercise accuracy and quality of life in knee osteoarthritis patients: a randomized controlled trial. *Archives of Orthopaedic and Trauma Surgery*, 143(2), 729-738. <https://doi.org/10.1007/s00402-021-04149-8>
39. Wierzbicki, M. P., Jantos, B. A., Tomaszewski, M. (2024). A review of approaches to standardizing medical descriptions for clinical entity recognition:

- implications for artificial intelligence implementation. *Applied Sciences*, 14(21), 9903. <https://doi.org/10.3390/app14219903>
40. Xu, Y., Ye, W., Song, Q., Shen, L., Liu, Y., Guo, Y., Liu, G., Wu, H., Wang, X., Sun, X., Bai, L., Luo, C., Liao, T., Chen, H., Song, C., Huang, C., Wu, Y., Xu, Z. (2022). Using machine learning models to predict the duration of the recovery of COVID-19 patients hospitalized in Fangcang shelter hospital during the Omicron BA. 2.2 pandemic. *Frontiers in Medicine*, 9, 1001801. <https://doi.org/10.3389/fmed.2022.1001801>
41. Yun, D., Choi, J. (2019). Person-centered rehabilitation care and outcomes: a systematic literature review. *International Journal of Nursing Studies*, 93, 74-83. <https://doi.org/10.1016/j.ijnurstu.2019.02.012>
42. Zhu, Y., Wang, C., Li, J., Zeng, L., Zhang, P. (2023). Effect of different modalities of artificial intelligence rehabilitation techniques on patients with upper limb dysfunction after stroke – a network meta-analysis of randomized controlled trials. *Frontiers in Neurology*, 14, 1125172. <https://doi.org/10.3389/fneur.2023.1125172>

dr Robert Lizak¹

Uniwersytet Pomorski w Słupsku

BARIERY WYKORZYSTANIA AI W REDUKCJI EROZJI BAZY PODATKOWEJ CIT W POLSCE NA TLE KONTROLI NIK

BARRIERS TO THE USE OF AI IN REDUCING CIT TAX BASE EROSION IN POLAND IN THE CONTEXT OF THE SUPREME AUDIT OFFICE'S AUDIT

Streszczenie

W rozdziale podjęto problem erozji bazy podatkowej CIT w Polsce i możliwości jego ograniczenia z wykorzystaniem sztucznej inteligencji (AI) w świetle ustaleń kontroli NIK z lat 2019 i 2024. Punkt wyjścia stanowi wysoka szacunkowa luka CIT (ok. 26 mld zł, ok. 30% teoretycznych dochodów), brak metodologii pomiaru tej luki oraz strategii jej przeciwdziałania. Wyniki kontroli NIK ukazały systemową lukę informacyjną, w tym brak ponad 1 250 400 zeznań CIT-8 i 58 900 zgłoszeń NIP-8, deficyt specjalistycznego know-how w obszarze CIT oraz niską efektywność czynności sprawdzających i kontroli, zwłaszcza w niewyspecjalizowanych urzędach skarbowych. Okoliczności te w istotny sposób ograniczają możliwość efektywnego wykorzystania potencjału narzędzi AI. W rozdziale przyjęto tezę, że efektywne wykorzystanie AI do ograniczenia erozji bazy CIT wymaga najpierw uzupełnienia luki informacyjnej,

¹ <https://orcid.org/0000-0001-7980-2409>, e-mail: robert.lizak@upsl.edu.pl

Lizak, R. (2026). Bariery wykorzystania AI w redukcji erozji bazy podatkowej CIT w Polsce na tle kontroli NIK. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 75-95). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_5

wzmocnienia kompetencji i specjalizacji w CIT oraz uporządkowania procesów egzekucyjnych i kontrolnych.

Słowa kluczowe: erozja bazy podatkowej CIT, zarządzanie ryzykiem podatkowym, cyfryzacja administracji podatkowej, sztuczna inteligencja w administracji podatkowej, zgodność podatkowa oparta na danych AI

Abstract

The chapter addresses the problem of CIT tax base erosion in Poland and the possibility of limiting it with the use of artificial intelligence (AI) in light of the findings of the Supreme Audit Office (NIK) audits from 2019 and 2024. The starting point is the high estimated CIT gap (approximately PLN 26 billion, approximately 30% of theoretical revenues), the lack of a methodology for measuring this gap, and the lack of a strategy to counteract it. The results of the NIK audit revealed a systemic information gap, including the absence of over 1,250,400 CIT-8 tax returns and 58,900 NIP-8 notifications, a deficit of specialist know-how in the area of CIT, and the low effectiveness of verification and control activities, especially in non-specialized tax offices. These circumstances significantly undermine the effective use of AI potential based on the existing data infrastructure of the National Revenue Administration and within the regulatory framework of the EU AI Act. The chapter argues that the effective use of AI to reduce CIT base erosion first requires filling the information gap, strengthening CIT expertise and specialization, and streamlining enforcement and control processes.

Keywords: CIT tax base erosion, tax risk management, artificial intelligence in tax administration, digitalisation of tax administration, AI data driven tax compliance

Wstęp

Proces erozji bazy podatkowej polegający na działaniu podatników dążących do obniżenia podstawy opodatkowania poprzez przenoszenie dochodów, generowanie sztucznych kosztów lub wykorzystywanie luk konstrukcyjnych systemów podatkowych stanowi niebotyczne wyzwanie dla wszystkich organów administracji skarbowej i państw na świecie, w których władza działa na podstawie prawa (Crivelli, de Mooij, Keen, 2015; OECD, 2013, s. 9; EC, 2018, s. 3). Mało tego, erozja bazy podatku dochodowego od osób prawnych (ang. *corporate income tax* – CIT), jest problemem narodowym, regionalnym i globalnym (Gajewski, 2017, s. 443-445), który w dużej mierze powstaje w następstwie stosowania agresywnych strategii planowania podatkowego, co

umożliwia transfer zysków do jurysdykcji o niskim lub zerowym opodatkowaniu (NIK, 2019). Sytuacja nie wygląda inaczej w Polsce, choć sprawa wydaje się być nadzwyczaj poważna, dlatego że do 2023 r. nie opracowano strategii rozwiązania problemu erozji bazy podatkowej CIT, w tym z wykorzystaniem AI (Sarnowski i Selera, 2020, s. 29-50). Nie oszacowano również aktualnej wartości luki CIT i jej struktury (Konopczak, Łożykowski, 2019, s. 25-55), zarówno w odniesieniu do działalności podatników w wymiarze krajowym, jak i zagranicznym. Z raportu Polskiego Instytutu Ekonomicznego opublikowanego w 2022 r. wynika, że w 2020 r. szacowana luka CIT w Polsce wyniosła 26 mld PLN, co stanowiło około 30 proc. teoretycznych dochodów z tego podatku (Sawulski i in., 2022).

W latach 2019 i 2024 opublikowano wyniki kontroli Najwyższej Izby Kontroli (NIK) w obszarze CIT, najpierw w przedmiocie skuteczności i rzetelności przeciwdziałania agresywnej optymalizacji podatkowej, a później w obrębie prawidłowości i rzetelności nadzoru nad prawidłowością rozliczeń CIT. Wyniki obu kontroli wskazują na poważne problemy systemowe w zakresie nadzoru nad prawidłowością rozliczeń CIT, i to nie z tego powodu, że efektywność administracji skarbowej w obszarze zwalczania luki CIT pozostawia wiele do życzenia, ale ze względu na skalę zaniedbań. W przypadku kontroli NIK z 2019 r. uznano, że ze względu na brak oszacowania luki podatkowej oraz brak metodologii jej liczenia nie jest możliwa jednoznaczna ocena, czy podejmowane działania przez administrację skarbową były adekwatne do przyczyn powstania luki i jej wielkości oraz czy były skuteczne i jaki miały wpływ na wzrost łącznych dochodów z tytułu CIT (NIK, 2019, s. 10). Niestety, w kontroli z roku 2024 podtrzymano, że nadal nie opracowano przedmiotowej metodologii, choć w 2023 r. podjęto działania zmierzające do zastosowania metody odgórnej, nawiązując współpracę z Głównym Urzędem Statystycznym (NIK, 2024, s. 30). W kontroli NIK z 2024 r. postawiono tezę, że nadzór organów Krajowej Administracji Skarbowej (KAS) nad prawidłowością rozliczeń CIT podatników pozostających we właściwości naczelników niewyspecjalizowanych urzędów skarbowych (nUS) nie był w pełni prawidłowy i rzetelny. W tym przypadku zatrważający jest choćby fakt, że względem podatników CIT pozostających we właściwości naczelników ww. urzędów, którzy stanowili w 2022 r. 96 procent wszystkich podatników CIT (w liczbie bliskiej 1 mln), liczba brakujących zeznań CIT-8 za lata 2017-2022 wyniosła we wszystkich nUS ponad

1250,4 tys. (tj. 90 procent brakujących zeznań ogółem)², a liczba niezłożonych zgłoszeń NIP-8 przez podmioty zarejestrowane w Krajowym Rejestrze Sądowym wynosiła 58,9 tys., w tym 58,3 tys. zgłoszeń (99 procent) dotyczyło podatników podlegających pod nUS³.

Nie jest niczym odkrywczym, że wykorzystanie sztucznej inteligencji (ang. *artificial intelligence* – AI) w administracji może zwiększyć jej efektywność (Lizak, 2024; Bogucki, 2025, s. 30; Hadwick, 2024, s. 939-940; Mółka, Jimenez, 2025, s. 264), w tym w administracji skarbowej (Shaikh, 2025; OECD, 2025a; OECD, 2025b; IMF, 2025). Doświadczenia administracji podatkowych państw OECD wskazują, że narzędzia oparte na analizie danych i uczeniu maszynowym mogą znacząco zwiększyć skuteczność identyfikacji ryzyk podatkowych oraz wykrywania nieprawidłowości podatkowych. Jednocześnie podkreśla się, że efektywność tych rozwiązań pozostaje silnie uzależniona od jakości danych wejściowych, kompetencji analitycznych administracji oraz właściwego zaprojektowania procesów instytucjonalnych (OECD, 2025a; OECD, 2025b). Dzieje się tak z kilku powodów. Po pierwsze, nie można wykluczyć, że administracja skarbową jest prawdopodobnie jednym z największych „producentów” danych w całej administracji (The White House, 2020). Skalę tej „produkcji” odzwierciedla istniejąca w Ministerstwie Finansów (MF) Centralna Hurtownia Danych (CHD), w której składowane są dane z wewnętrznych systemów, w tym podatkowych, celnych, akcyzowych, a także źródeł zewnętrznych, w tym kursy walut, dane statystyczne lub dane z Poczty Polskiej (Rada Ministrów, 2026, s. 14). Po drugie, CHD jest systemem analitycznym składającym się z warstwy składowania danych (bazy danych), narzędzi do integracji danych (ang. *extract, transform, load* – ETL) oraz warstwy raportowej oraz narzędzi do analizy danych. Po trzecie, regularne uczenie modeli AI na zróżnicowanych danych pozwala administracji podatkowej identyfikować zarówno znane, jak i pojawiające się nowe formy nieprawidłowości, dzięki czemu działania analityczne i kontrolne stają się bardziej precyzyjne,

² Zeznanie CIT-8 dotyczy wysokości osiągniętego dochodu (poniesionej straty) i należnego podatku dochodowego od osób prawnych. Należy je złożyć do urzędu skarbowego (wraz z załącznikami) za pomocą środków komunikacji elektronicznej. Termin złożenia CIT-8 upływa z końcem trzeciego miesiąca następującego po zakończeniu roku podatkowego.

³ Zgłoszenie NIP-8 jest zgłoszeniem identyfikacyjnym i aktualizacyjnym w zakresie danych uzupełniających.

proporcjonalne i ukierunkowane na realne ryzyka (Engstrom i in., 2020, s. 26). Wreszcie po czwarte, w dniu 13 czerwca 2024 r. Parlament Europejski i Rada (UE) przyjęły tzw. „EU AI Act” (akt w sprawie sztucznej inteligencji, 2024), stanowiący pierwszy akt prawny w Unii Europejskiej (UE), którego celem jest poprawa funkcjonowania rynku wewnętrznego przez ustanowienie jednolitych ram prawnych, w szczególności w zakresie rozwoju, wprowadzania do obrotu, oddawania do użytku i wykorzystywania systemów sztucznej inteligencji⁴. Ze wstępnej oceny EU AI Act wynika, że wykorzystanie AI w podatkowych postępowaniach administracyjnych i karnoskarbowych jest dozwolone, ale różnie klasyfikowane ze względu na stopień ryzyka (Kuźniacki i in., 2022, s. 573-616).

W praktyce administracji skarbowych państw OECD algorytmy analityczne oraz narzędzia AI są już wykorzystywane w wielu obszarach związanych z zarządzaniem ryzykiem podatkowym i przeciwdziałaniem unikaniu opodatkowania. Wybrane przykłady takich zastosowań przedstawiono w Tabeli 1.

Tabela 1. Przykłady wykorzystania algorytmów i AI w administracjach skarbowych

Obszar zastosowania	Przykład narzędzia	Funkcja analityczna
Analiza ryzyka podatkowego	Modele predykcyjne	Identyfikacja podatników o podwyższonym ryzyku nieprawidłowości
Wykrywanie schematów unikania opodatkowania	Algorytmy sieciowe	Analiza powiązań kapitałowych i transakcyjnych
Automatyczna selekcja do kontroli	Scoring podatkowy	Typowanie podmiotów do kontroli podatkowej
Analiza dokumentów podatkowych	NLP (Natural Language Processing)	Automatyczna analiza deklaracji, raportów i dokumentacji
Wykrywanie anomalii	Uczenie maszynowe	Identyfikacja nietypowych wzorców zachowań podatników

Źródło: opracowanie własne na podstawie: OECD, 2025a, s. 94-99; 2025b, s. 39-42; Engstrom i in., 2020, s. 26-30; Shaikh, 2025, s. 8-11.

⁴ Zgodnie z art 3 pkt 1 EU AI Act, „system AI” oznacza system maszynowy, który został zaprojektowany do działania z różnym poziomem autonomii po jego wdrożeniu oraz który może wykazywać zdolność adaptacji po jego wdrożeniu, a także który – na potrzeby wyraźnych lub dorozumianych celów – wnioskuje, jak generować na podstawie otrzymanych danych wejściowych wyniki, takie jak predykcje, treści, zalecenia lub decyzje, które mogą wpływać na środowisko fizyczne lub wirtualne.

Celem niniejszej publikacji jest ocena możliwości wykorzystania technologii sztucznej inteligencji do ograniczenia erozji bazy podatkowej CIT w Polsce w kontekście wyników kontroli NIK opublikowanych w latach 2019 i 2024 w obszarze CIT. Powyższa ocena jest nieodzowna do odpowiedzi na pytanie, czy zintegrowane wykorzystanie AI w obszarach danych, kompetencji i procesów, umożliwi zwiększenie wykrywalności nieprawidłowości, efektywności nadzoru i egzekucji, co w konsekwencji ułatwi ograniczenie erozji bazy podatkowej CIT w Polsce. W celu odpowiedzi na tak postawione pytanie dokonano przeglądu ww. wyników kontroli NIK, a następnie wyodrębniono szereg problemów w trzech obszarach, tj. dane, kompetencje i procesy, z podaniem proponowanej możliwości ich rozwiązania (Tabela 2).

Tabela 2. Główne bariery wykorzystania AI w ograniczeniu erozji bazy podatkowej CIT

Obszar bariery	Zidentyfikowane problemy	Konsekwencje dla wykorzystania AI
Dane (luka informacyjna)	Brak ponad 1 250 400 zeznań CIT-8 oraz 58 900 zgłoszeń NIP-8; brak metodologii pomiaru luki CIT	Ograniczona możliwość analizy ryzyka podatkowego oraz trenowania modeli AI
Kompetencje (know-how)	Niedobór specjalistów w zakresie CIT, rotacja pracowników, niewystarczające szkolenia oraz brak specjalizacji analitycznej	Ograniczona zdolność projektowania modeli ryzyka i interpretacji wyników analitycznych
Procesy (egzekucja i kontrola)	Niska liczba kontroli CIT, brak konsekwencji w egzekwowaniu obowiązków deklaracyjnych, fragmentaryczne zarządzanie ryzykiem	Ograniczona skuteczność wykorzystania narzędzi analitycznych i AI w praktyce administracji skarbowej

Źródło: opracowanie własne na podstawie ustaleń kontroli NIK (2019; 2024).

O ile wspomniane wcześniej EU AI Act nie reguluje wprost podatków, to określa ramy prawne i techniczne umożliwiające wykorzystanie AI w obszarze podatków. Dla przykładu, EU AI Act określa zakres przetwarzania danych przez AI, wprowadza obowiązek zapewnienia transparentności i nadzoru człowieka, co ma istotne znaczenie dla praw podatnika, aż wreszcie wspiera interoperacyjność systemów informatycznych w ramach UE i OECD. Przegląd wyników kontroli NIK uzupełniono tezami z innych dokumentów organów władzy publicznej i organizacji międzynarodowych, a także z szeregu innych przepisów prawa *hard law* i *soft law* oraz poglądów w literaturze przedmiotu,

które w sposób bezpośredni lub pośredni są powiązane z ograniczeniem erozji bazy podatkowej CIT z wykorzystaniem AI.

Luka informacyjna w bazie podatkowej CIT

Luka informacyjna to rozbieżność między informacją, której odbiorca potrzebuje lub oczekuje, a tą, do której faktycznie ma dostęp i może ją przetworzyć (Loewenstein, 1994, s. 75-98; Filipczak-Białkowska, 2019, s. 245-262). Im większy zakres ww. rozbieżności, czyli im większy niedobór informacji, tym bardziej doniosły jest jej negatywny wpływ na zarządzanie danymi i funkcjonowanie organizacji. Jak już wspomniano, w trakcie kontroli NIK w MF ustalono, że według stanu na koniec I półrocza 2023 r., liczba brakujących zeznań CIT-8 za lata 2017-2022 wyniosła we wszystkich nUS ponad 1250,4 tys., czyli 90 procent brakujących zeznań ogółem (NIK, 2024, s. 11). Można uznać to nawet za swego rodzaju „szarą strefę dochodów CIT”. W pierwszej kolejności zasadne jest więc postawienie tezy, że państwo nie zna faktycznej wielkości bazy CIT, ponieważ nie ma dostępu do informacji wskazywanych w zeznaniu CIT-8, w tym informacji o wysokości przychodów, kosztach uzyskania przychodów, dochodzie lub stracie, transakcjach wewnątrzgrupowych i podstawie opodatkowania. Oczywistym jest, że w takiej sytuacji nie ma możliwości zwerifikowania tej bazy i ograniczenia jej erozji. W następnej kolejności brak wolumenu zeznań CIT-8 w takiej skali może ułatwiać lub zachęcać do ukrywania dochodu, zaniżania podstawy opodatkowania, tworzenia fikcyjnych kosztów lub transferu zysków, co w konsekwencji zwiększa przestrzeń dla agresywnej optymalizacji. Wreszcie wysoka skala braku zeznań CIT-8 zwiększa słabość administracji podatkowej do wykrywania ryzyk i prowadzenia kontroli CIT, bowiem ograniczona jest zdolność do typowania podmiotów do kontroli, oceny ryzyka, prowadzenia analityki danych, szacowania luki CIT, a także nadzoru nad podatnikami pozostającymi we właściwości nUS (NIK, 2019, s. 2516; NIK, 2024, s. 38, 40-43 i 71) (Tabela 3).

Tabela 3. Skutki luki informacyjnej w bazie podatkowej CIT

Zjawisko	Skala problemu (ustalenia NIK)	Konsekwencje dla administracji skarbowej
Brak zeznań CIT-8	Ponad 1 250 400 brakujących zeznań za lata 2017-2022	Brak dostępu do danych o przychodach, kosztach, dochodzie lub stracie, transakcjach wewnątrzgrupowych i podstawie opodatkowania
Brak zgłoszeń NIP-8	58 900 niezłożonych zgłoszeń	Brak danych identyfikujących podatników (adres, reprezentacja, PKD, miejsce działalności)
Ograniczony dostęp do danych podatkowych	Brak podstawowych informacji deklaracyjnych	Utrudniona analiza ryzyka podatkowego oraz typowanie podmiotów do kontroli
Niespójność danych w systemach administracji	Brak możliwości powiązania danych	Utrudnione łączenie danych CIT z VAT, JPK i innymi bazami danych

Źródło: opracowanie własne na podstawie ustaleń NIK (2019; 2024).

Z kontroli NIK z 2024 r. wynika, że podobna sytuacja przedstawia się z liczbą niezłożonych zgłoszeń NIP-8 przez podmioty zarejestrowane w Krajowym Rejestrze Sądowym, która wyniosła 58,9 tys., w tym 58,3 tys. zgłoszeń (99 procent) dotyczyło podatników podlegających pod nUS. Brak dostępu do informacji ze zgłoszenia NIP-8 oznacza niemożność dostępu do podstawowych danych identyfikujących podatnika, w tym adresu, danych o reprezentacji, danych kontaktowych, Polskiej Klasyfikacji Działalności lub miejsca prowadzenia działalności, co umożliwia i ułatwia rejestrowanie podmiotów nieaktywnych lub fikcyjnych oraz transfer zysków lub kosztów bez opodatkowania. Ponadto, brak podstawowych informacji nt. podatnika utrudnia analizę danych podatkowych, chociażby poprzez niemożność ich przyporządkowania do innych danych, dla przykładu z danymi z podatku od towarów i usług, Jednolitego Pliku Kontrolnego lub Systemu Teleinformatycznego Izby Rozliczeniowej (Skuza, Lizak, 2017, s. 195-208). Nie sposób nie wspomnieć, że zidentyfikowane 58 tys. podmiotów, które nie wypełniły obowiązku złożenia NIP-8, które stanowią największy i najbardziej ryzykowny segment podatników, oznacza, że administracja skarbową ma ograniczone możliwości trafnego typowania podmiotów o wysokim ryzyku. Powyższe prowadzi do wniosku, że z jednej strony mamy niejako „szarą strefę nieuwierzytelnionych podatników CIT”, co ułatwia powstawanie podmiotów fikcyjnych i struktur wykorzystywanych do

erozji bazy CIT, a z drugiej strony brak danych osłabia systemowe mechanizmy przeciwdziałania zaniżaniu podstawy opodatkowania CIT, co zwiększa zakres erozji bazy CIT.

Zasoby danych stanowią podstawowe środowisko funkcjonowania systemów sztucznej inteligencji. Przed implementacją rozwiązań AI kluczowe jest ograniczenie luki informacyjnej oraz zapewnienie wysokiej jakości i spójności danych wejściowych. W ocenie autora niniejszej publikacji nie jest możliwe prawidłowe oszacowanie luki CIT oraz ograniczenie erozji bazy podatkowej CIT bez uprzedniego wyegzekwowania złożenia zeznań CIT-8 i zgłoszeń NIP-8. *Prima facie* wydaje się zasadne, aby najpierw wykorzystać AI do niezwłocznego zmniejszenia luki informacyjnej w bazie CIT. Z prawa podatkowego można wyodrębnić wiele przepisów, które umożliwiają wyegzekwowanie obowiązku złożenia zeznań CIT-8, co przedstawiono w poniższej Tabeli 4.

Tabela 4. Instrumenty prawne egzekwowania obowiązku złożenia CIT-8 i NIP-8

Instrument prawny	Podstawa prawna	Funkcja w egzekwowaniu obowiązków CIT
Sankcja za niezłożenie informacji podatkowej	art. 80 ustawy Kodeks karny skarbowy, „k.k.s.”	odpowiedzialność karna skarbową za brak deklaracji
Wezwanie do złożenia wyjaśnień	art. 274a O.p.	ustalenie przyczyn niezłożenia deklaracji
Kara porządkowa	art. 262 Ordynacji podatkowej, „O.p.”	sankcja procesowa za niewykonanie obowiązków
Oszacowanie podstawy opodatkowania	art. 23 O.p.	ustalenie dochodu w przypadku braku deklaracji
Odmowa wydania zaświadczenia o niezaleganiu	art. 306e § 1 pkt 2 O.p. w zw. art. 27 ust. 1 ustawy o podatku dochodowym od osób prawnych, „ustawa CIT”	instrument dyscyplinujący podatników
Czynności sprawdzające	art. 272 O.p.	weryfikacja prawidłowości rozliczeń
Typowanie do kontroli podatkowej	art. 2 ust. 2 pkt 1 i 2 w zw. z art. 33 ust. 2 ustawy o Krajowej Administracji Skarbowej, 2016; art. 23 § 1 O.p.; art. 21 § 3 O.p.; art. 53 § 1 O.p.	identyfikacja podatników o podwyższonym ryzyku
Odpowiedzialność członków zarządu	art. 116 § 1 O.p.	zwiększenie presji na dochodzenie obowiązków podatkowych

Źródło: opracowanie własne na podstawie przepisów prawa podatkowego.

Niektóre powyższe podstawy mają również zastosowanie w przypadku niedochowania obowiązku złożenia NIP-8. Dodatkowo, istnieje możliwość zastosowania sankcji za niewywiązanie się z obowiązków informacyjnych (art. 81 § 1 k.k.s.) lub podanie danych nieprawdziwych lub zatajenie danych (art. 83 § 1 k.k.s.), jak również zastosowanie sankcji za niewywiązanie się z obowiązku zgłaszania i aktualizacji informacji o beneficjencie rzeczywistym (art. 58 w zw. z art. 153 ust. 3 i art. 60a ustawy o przeciwdziałaniu praniu pieniędzy oraz finansowaniu terroryzmu, 2018, „ustawa AML”). Autor niniejszej publikacji stoi na stanowisku, że potencjalnie możliwe byłoby wyegzekwowanie obowiązku polegającego na złożeniu zeznań CIT-8 i zgłoszeniu NIP-8 z wykorzystaniem AI, chociażby poprzez:

- automatyczne generowanie spersonalizowanych wezwań do zrealizowania ww. obowiązków opartych na predykcji zachowań podatników (art. 274a i art. 262 O.p.);
- oszacowanie dochodu z użyciem danych porównawczych (art. 23 O.p.);
- identyfikację podatników z brakiem zeznań CIT-8 i automatyczne blokowanie zwrotów w przypadku podatku od towarów i usług (art. 87 ust. 2 i ust. 6 ustawy o podatku od towarów i usług, 2004, „ustawa VAT”; art. 274b § 1 O.p.) oraz WHT (art. 28b ust. 4 lub art. 26 ust. 7g ustawa CIT), a w przypadku zwrotów innych podatków na podstawie zasady ogólnej (art. 76b § 1 O.p.).

Ponadto, wykorzystanie AI mogłoby polegać na sprawdzaniu kompletności obowiązków podatkowych przed wydaniem zaświadczenia o niezaleganiu (art. 306e § 1 pkt 2 O.p.), a także automatycznym generowaniu alertów dla członków zarządu o ryzyku osobistej odpowiedzialności (art. 116 O.p.). Z kolei w przypadku zwiększenia wolumenu dochowania obowiązku złożenia NIP-8, wykorzystanie AI mogłoby sprowadzać się do automatycznego generowania wezwania wysyłanego przez SMS/e-mail/e-PUAP (art. 274a O.p. i art. 9 ustawy o zasadach ewidencji i identyfikacji podatników i płatników, 1995), identyfikowania podatników o najwyższym prawdopodobieństwie złożenia NIP-8 po pierwszej grzywnie porządkowej (art. 262 § 1 O.p.). Do innych przykładów można zaliczyć działania polegające na rozsyłaniu systemowego alertu do podatników narażonych na ryzyko odmowy zaświadczenia o niezaleganiu (art. 306e O.p.), wykrywanie przypadków wadliwych danych rejestrowych

wskazujących na naruszenie brzmienia art. 81-83 k.k.s., aż wreszcie działania polegające na analityce zgodności danych (*entity resolution*) między Krajowym Rejestrem Sądowym (ustawa o Krajowym Rejestrze Sądowym, 1997), Centralnym Rejestrem Beneficjentów Rzeczywistych (ustawa AML) i NIP-8.

W wielu państwach administracje podatkowe wykorzystują już systemy analityki danych i narzędzia oparte na AI w celu identyfikacji ryzyk podatkowych i przeciwdziałania unikaniu opodatkowania. Przykładowo, amerykańska administracja podatkowa (ang. *Internal Revenue Service* – IRS) stosuje modele analityczne, takie jak *Discriminant Function System* oraz *Large Partnership Compliance Model*, które wykorzystują uczenie maszynowe do identyfikacji deklaracji podatkowych o podwyższonym ryzyku nieprawidłowości (IRS, 2024). W Wielkiej Brytanii administracja HMRC wykorzystuje system Connect, który integruje dane z wielu źródeł i wykorzystuje analizę powiązań do wykrywania oszustw podatkowych. Z kolei administracje podatkowe Australii i Danii stosują modele predykcyjne i narzędzia analityki big data w celu zarządzania ryzykiem podatkowym i automatycznego typowania podmiotów do kontroli (OECD, 2025a; OECD, 2025b).

Know-how i potencjał analityczny służb skarbowych

Mimo, że w następstwie przeglądu kontroli NIK z 2024 r. wyodrębniono wiele problemów w obszarze wiedzy i potencjału analitycznego służb skarbowych, to zsyntetyzowano je do dwóch najbardziej doniosłych zagadnień. Po pierwsze, w nUS istnieje systemowy deficyt dedykowanej wiedzy w obszarze CIT. Za przyjęciem tak postawionej tezy przemawia szereg argumentów, w tym: 1) niedostateczna liczba pracowników z odpowiednią wiedzą i doświadczeniem w zakresie CIT, co wskazano w przypadku 8 z 16 Izb Administracji Skarbowej (IAS); 2) rotacja pracowników uniemożliwiająca ciągłe kształcenie się, zdobywanie doświadczenia i dzielenie się wiedzą, która to rotacja w dużej mierze jest spowodowana niekonkurencyjnymi warunkami płacowymi; 3) niedostateczna podaż szkoleń w zakresie CIT; 4) jednoczesne obciążenie pracowników zadaniami związanymi z VAT i podatkiem dochodowym od osób fizycznych, jak również brak wyodrębnienia specjalizacji w obszarze „analityka CIT”; 5) kierownictwo KAS nie dysponuje analizą w przedmiocie znaczącej dysproporcji dotyczącej liczby pracowników zajmujących się weryfikacją

rozliczeń CIT w ramach czynności sprawdzających lub kontroli podatkowych, w stosunku do liczby podlegających im podatników. Nie ulega wątpliwości, że AI jest nadal uzależniona od ludzkiej inteligencji, wiedzy i doświadczenia (tzw. *human in the loop*). Mówiąc inaczej, modele AI nie mogą zastąpić analityka CIT, który w docelowym modelu określa kryteria ryzyka, definiuje dane wejściowe, waliduje wyniki i zestawia je z przepisami prawa i praktyką gospodarczą. Wreszcie, wspomniane wcześniej istnienie „szarej strefy nieuwierzytelnionych podatników CIT” oraz „szarej strefy dochodów CIT”, utrudnia albo wręcz uniemożliwia adekwatne zaprojektowanie zapotrzebowania kadrowego i wiedzy specjalistycznej względem obszarów o wysokim ryzyku (np. duże grupy kapitałowe, złożone struktury transgraniczne).

Niemniej ważnym zagadnieniem jest nieefektywne zarządzanie potencjałem analitycznym i nieuzasadniona ocena ryzyka. Z wyników kontroli NIK z 2024 r. wynika, że w wielu nUS w ogóle nie podejmowano jakichkolwiek działań wobec podatników, którzy nie złożyli zeznania CIT-8. Stało się tak z powodu obciążenia wieloma innymi obowiązkami, a w przypadku podjęcia działania ograniczyły się one do jedno- lub dwukrotnego wezwania, które pozostawiono bez dalszego rozpoznania. Ponadto, w opinii nUS ryzyko erozji bazy podatkowej związane z CIT jest niskie w zestawieniu z VAT, działania podjęte względem CIT są mniej opłacalne niż VAT, CIT jest postrzegany jako bardziej złożony, a błędy w CIT są rzadsze. Trudno domniemać, na czym oparte są powyższe opinie, choćby w zakresie mniejszej opłacalności CIT względem VAT, skoro nie ma metodologii ustalania luki CIT i zidentyfikowano deficyt danych o uwierzytelnionych podatnikach i dochodach CIT. Wreszcie nie sposób nie dostrzec, że NIK trafnie wyodrębnił brak holistycznej oceny skali i skutków dysproporcji obciążenia zadaniami nUS oraz przyrostu liczby podatników CIT, co może przesądzać o braku materializowania się koncepcji zarządzania strategicznego.

Niestety, przywołane powyżej opinie nUS z kontroli NIK z 2024 r. nie są przychylne dla wykorzystania AI w ograniczeniu erozji bazy podatkowej CIT, ponieważ działania nUS i KAS kończą się na ignorowanych wezwaniach, braku dalszej eskalacji i słabym dokumentowaniu wyników, co właściwie całkowicie zubaża materiał do trenowania i oceny modeli ryzyka. Zatrważająca jest narracja o mniejszej opłacalności CIT względem VAT nie tylko dlatego, że nie jest oparta na danych, ale przede wszystkim z tego powodu, że nawet

gdyby wygenerowano listę podatników CIT z wykorzystaniem AI o wysokim ryzyku, to prawdopodobne jest, że w obecnych realiach byłaby on zignorowana ze względu na priorytetowe zwalczanie luki VAT. Co istotne, brak holistycznych analiz w przedmiocie obciążeń roboczogodzin pracowników nUS i KAS, a także brak systemowego podejścia do zarządzania ryzykiem i zasobami na podstawie zasobów bazodanowych, utrudnia wykorzystanie AI do optymalizacji alokacji zasobów w stopniu wyższym niż marginalny.

Powyższe prowadzi do wniosku, że wykorzystanie AI do ograniczenia erozji bazy CIT powinno nastąpić po uprzednim zmniejszeniu deficytu know-how, które mogą stanowić podstawową barierę dla efektywnego wykorzystania AI. Podobnie sytuacja się przedstawia z niewykorzystanym potencjałem analitycznym, nietrafną oceną ryzyka względem CIT i nieadekwatnym wykorzystaniem istniejących narzędzi prawnych. Wynika z tego, że bez strategicznego podejścia do zarządzania ryzykiem i zasobami oraz zdefiniowania procesów podejmowania decyzji, nie uda się w rzeczywistości efektywnie ograniczyć erozji bazy podatkowej CIT z wykorzystaniem AI. Nie oznacza to, że wykorzystanie AI jest bezzasadne i nie można z pomocą tej technologii złagodzić skutków ww. problemów, choćby poprzez uzupełnienie luki kompetencyjnej. W tym obszarze wartym rozważenia jest ustanowienie funkcji wirtualnego analityka CIT, który byłby swego rodzaju asystentem pracownika nUS i wspierałby go w analizie sprawozdań finansowych, ustalaniu statusu transakcji i istoty struktur kapitałowych, co umożliwiłoby automatyczne i predykcyjne identyfikowanie odchyleń od wzorców rynkowych oraz generowanie wstępnych hipotez ryzyka, zwłaszcza w obszarze cen transferowych, finansowania dłużnego i kwalifikacji kosztów.

Z kolei w wymiarze instytucjonalnym AI mogłoby wesprzeć KAS w zwiększeniu efektywności procesu szkolenia pracowników KAS i postępowania według określonych standardów, zwłaszcza poprzez generowanie scenariuszy edukacyjnych adekwatnych do kompetencji pracowników i zakresu obowiązków. Z jednej strony usprawniono by kształcenie pracowników w obszarze CIT, w szczególności nowoprzyjętych lub przesuniętych do zwalczania luki CIT, a z drugiej strony zmniejszono by negatywne konsekwencje rotacji kadrowej. Wreszcie w wymiarze analitycznym, wykorzystanie AI umożliwiłoby zwiększenie efektywności wyników zestawiania masowych danych z różnych dokumentów i zasobów bazodanowych, i co ważne, pozwoliłoby ustalać

jednolite standardy analityczne dla różnych podatników, czyli odwrotnie aniżeli dotychczas, gdy stosowano te same kryteria wobec wszystkich podatników niezależnie od rozmiarów ich działalności.

Efektywność czynności sprawdzających i kontroli podatkowej w zakresie rozliczeń CIT

Z ustaleń NIK wynika, że w administracji skarbowej istnieje skala zaniedbań w egzekwowaniu podstawowych obowiązków CIT-8, która ma charakter systemowy. Za przyjęciem tak postawionej tezy przemawia fakt, że w nUS nie podjęto adekwatnych działań w następstwie niedochowania obowiązków podatnika CIT, w tym nie wzywano osób reprezentujących podatników, nie weryfikowano adresów, nie stosowano kar porządkowych (art. 262 O.p.), nie kierowano zawiadomień do organów prowadzących postępowanie karne skarbowe, ani nie wykorzystywano przewidzianych w przepisach prawa administracyjnego narzędzi dyscyplinujących. Sprawa jest poważna, ponieważ liczba kontroli CIT była skrajnie niska. W latach 2017-2022 przeprowadzono łącznie 1900 kontroli, czyli średnio zaledwie dwie rocznie na każdy nUS. Co ważne, w przypadku 100 urzędów stanowiących 26 procent z łącznej ich liczby, obsługujących ponad 44 tys. spółek prawa handlowego, nie przeprowadzono żadnej lub tylko jedną kontrolę CIT. Choć liczba czynności sprawdzających była wyższa (144 rocznie na jeden nUS), to miały one głównie charakter formalno-rachunkowy i nie przeprowadzono w ich ramach merytorycznej weryfikacji rozliczeń CIT. Mimo istnienia wytycznych MF (z 2017 i 2021 r.), w których wezwano do podjęcia działań zmierzających do sprawdzenia terminowości składania deklaracji, wezwania podatników do złożenia deklaracji, żądania złożenia wyjaśnień w sprawie przyczyn niezłożenia deklaracji oraz przedstawienia dokumentów, a także nałożenia kary porządkowej na podstawie art. 262 § 1 pkt 2 O.p., to w przypadku niezłożenia CIT-8 nie podjęto w nUS odpowiednich działań. Co istotne, NIK trafnie dostrzegł problem niewykorzystania dostępnych danych z VAT pod kątem ich wpływu na CIT, choć różnice między obrotami zadeklarowanymi w VAT a wykazanymi w CIT stanowią podstawową przesłankę ryzyka nieprawidłowości.

O ile podkreślenia wymaga fakt, że skala zaniechań wymaga głębszego zbadania, a zwłaszcza zestawienia ustaleń NIK z możliwościami aparatu skarbowego, to zasadne jest ustanowienie algorytmu AI umożliwiającego identyfikację podatników CIT o wysokim ryzyku, u których niezłożenie CIT-8 jest powiązane z działaniem poza systemem podatkowym, jak również identyfikację podatników o niskim prawdopodobieństwie niezgodności z prawem. Celem ustanowienia takiego algorytmu jest zwiększenie efektywności zarządzania zasobami administracji skarbowej oraz identyfikowanie i eliminowanie czynności zbędnych oraz niedających na końcu jakichkolwiek efektów lub wartości publicznej (Moore, 1995). Podobnie sytuacja się przedstawia w przypadku ustanowienia zautomatyzowanego procesu egzekwowania obowiązków deklaracyjnych, co miałyby z jednej strony zapobiec sytuacji opisanej przez NIK, w której sprawa kończy się na jednym nieodebranych wezwaniu pozostawionym w aktach, a z drugiej strony ułatwiłoby ciągłość i konsekwencję procesową, a docelowo zmniejszyłoby skalę niezłożonych zeznań CIT-8 i zgłoszeń NIP-8. Poza tym, na uwagę zasługuje automatyczne porównywanie danych z zeznań CIT i VAT, które dotychczas były wykonywane sporadycznie i „ręcznie”, a w niektórych urzędach skarbowych wcale. Wreszcie warto rozważyć jest wdrożenie modeli predykcyjnych umożliwiających automatyczne określanie prawdopodobieństwa naruszenia obowiązków podatkowych przez konkretnego podatnika. Jest to istotne o tyle, że w praktyce umożliwi identyfikację podmiotów najbardziej narażonych na niezgodność z prawem jeszcze przed wystąpieniem zaległości lub formalnych braków, czyli nastąpi zmiana modelu zarządzania z reaktywnego na proaktywny.

Z kontroli NIK wynika, że w nUS nie działały wyspecjalizowane zespoły odpowiedzialne za CIT, a zamiast tego zadania były rozproszone pomiędzy zespoły zajmujące się czynnościami analitycznymi i sprawdzającymi, działami kontroli podatkowej oraz działami PIT i VAT. Dodatkowo, zakresy obowiązków pracowników nUS były nieprecyzyjne i nie definiowały odpowiedzialności za proces rozliczeń CIT, a pracownicy CIT jednocześnie realizowali zadania z zakresu PIT i VAT. Czynności sprawdzające i kontrole CIT dotyczyły 12 procent wszystkich kontroli podatkowych, zaś udział kwoty uszczupień ujawnionych w CIT stanowił zaledwie 7 procent ogółu. Przegląd wyników kontroli NIK prowadzi do wniosku, że brak specjalizacji w nUS w obszarze CIT i brak macierzy odpowiedzialności pracowników i naczelników nUS

spowodowały niepodjęcie spraw lub pozostawianie ich poza zainteresowaniem analitycznym, stosowanie kontroli w sposób wybiórczy, a proces typowania podmiotów do kontroli miał charakter fragmentaryczny. W tym obszarze wykorzystanie AI mogłoby objąć zarządzanie sprawami CIT polegające na inteligentnym przydzielaniu zasobów ludzkich do zadań, a także stałym monitorowaniu procesów i wykrywaniu krytycznych barier. Tym bardziej, że w literaturze podkreśla się, że efektywność administracji podatkowej jest silnie powiązana z poziomem zdolności analitycznych oraz jakością zarządzania ryzykiem podatkowym (Baer, Barra, Benitez, 2025).

Podsumowanie

Prima facie wydaje się, że nastąpił idealny moment do wykorzystania AI do ograniczenia erozji bazy podatkowej CIT. Za postawieniem takiej tezy przemawiają co najmniej trzy argumenty. Po pierwsze, w następstwie przeglądu wyników kontroli NIK z 2019 r. i 2024 r. można dojść do wniosku, że dotychczas nie podjęto się na poważnie ograniczenia erozji bazy podatkowej CIT w Polsce, w tym z wykorzystaniem AI. Po drugie, mimo istotnych braków w dostępie do danych z zeznań CIT-8 i zgłoszeń NIK-8, zasób bazodanowy KAS jest na tyle szeroki, że ich analiza bez użycia technologii zaawansowanego przetwarzania danych nie jest możliwa, albo inaczej, jest niezwykle trudna i czasochłonna. Tym bardziej, że MF i KAS ma obecnie dostęp do danych z formularzy interaktywnych online zawierających informacje o cenach transferowych dla osób prawnych TPR-C(5) oraz danych o cenach transferowych dla osób fizycznych TPR-P(5), a także danych ze schematów podatkowych krajowych i transgranicznych (ang. *Mandatory Disclosure Rules* – MDR). Ponadto, od dnia 1 stycznia 2026 r. wejdzie w życie obowiązek przekazywania do MF dokumentów JPK CIT względem wszystkich firm, które są płatnikami VAT, czyli wysyłają cyklicznie plik JPK_V7, a w dniu 1 lutego 2026 r. rozpocznie działać Krajowy System e-Faktur (KSeF), który umożliwia wystawianie i udostępnianie faktur ustrukturyzowanych. Wreszcie po trzecie, przyjęte w prawie unijnym w roku 2024 rozporządzenie EU AI Act wyznacza ramy prawne i techniczne do wykorzystania AI, w tym zakresie ograniczenia erozji bazy podatkowej CIT.

Względem luki informacyjnej w bazie podatkowej CIT wysnuto dwa podstawowe wnioski. Z jednej strony luka informacyjna uniemożliwia dostęp do

podstawowych danych CIT i utrudnia prawidłową ocenę ryzyka, a z drugiej strony zmniejsza konkurencyjność podatników CIT, którzy systematycznie działają w sposób zgodny z prawem. Z kolei skala i zakres luki informacyjnej w bazie podatkowej CIT (brak 1 250 400 zeznań CIT-8 i 58 900 zgłoszeń NIP-8 w latach 2017-2022) właściwie przesądza o niemożności ustalenia w praktyce przez administrację skarbową podstawy opodatkowania i oszacowania luki CIT. W następnej kolejności można wysnuć wniosek, że luka informacyjna wynikająca z braku zeznań CIT-8 i zgłoszeń NIP-8 utrudnia, a w niektórych przypadkach uniemożliwia łączenie danych CIT, VAT i JPK, co pozbawia administrację skarbową sposobności trafnego typowania podmiotów do kontroli i wykrywania schematów erozji CIT. Wynika z tego, że w efekcie administracja skarbową działa bez realnej oceny ryzyka w obszarze CIT, która powinna być obiektywna, wszechstronna i ciągła, a w przypadku typowania do kontroli istnieje wysokie prawdopodobieństwo, że następuje ono na chybił trafił.

W obszarze kompetencji pierwszy wniosek sprowadza się do tego, że systemowy deficyt specjalistów CIT uniemożliwia sprawne i efektywne wykorzystanie nawet dostępnych danych i narzędzi prawnych, a może również stanowić podstawę nietrafnego domniemania, że CIT ma niskie znaczenie fiskalne, zwłaszcza w porównaniu z VAT. Niedobory wiedzy w obszarze CIT eskalują zakres zaniechań, co zubaża dane do uczenia się modeli AI, a w konsekwencji utrudnia zamianę modelu funkcjonowania z formuły reaktywnej na proaktywną. Wreszcie w przedmiocie efektywności czynności sprawdzających i kontroli podatkowych nasuwa się wniosek, że skala zaniechań w obszarze egzekucji ma charakter systemowy, a rozproszenie odpowiedzialności prowadzi do fragmentarycznego działania. Powyższe wnioski z poszczególnych części niniejszej publikacji pozwalają postawić wniosek o znaczeniu strategicznym, że zaniechanie niezwłocznego uzupełnienia luki informacyjnej, zwłaszcza zeznań CIT-8 i zgłoszeń NIP-8, brak kompetencji i wiedzy na temat CIT oraz niska efektywność zarządzania procesami egzekucyjnymi i kontrolnymi, łącznie stanowią barierę do efektywnego wykorzystania AI. Oznacza to brak danych wejściowych i informacji zwrotnej, jak również odpowiedniego otoczenia instytucjonalnego, co pozwala na adekwatną reakcję i generowanie z nich wartości.

W odpowiedzi zasadne jest zintegrowane, sekwencyjne i równoległe podejście do wykorzystania AI, pod warunkiem uprzedniego ustanowienia dostępu do danych wysokiej jakości, które będą dokładne, kompletne, rzetelne,

trafne i aktualne. Jak już wspomniano, dane dla AI są niczym wszechocean, dlatego wykorzystanie AI nie będzie efektywne dopóty, dopóki status braku zgłoszeń CIT-8 i NIP-8 nadal się utrzyma. W następnym kroku konieczne jest formalne ustanowienie algorytmów reakcji procesowej i drzew decyzyjnych w obszarze CIT, ale z uwzględnieniem holistycznego ujęcia ograniczenia erozji bazy podatkowej. Pozwoli to dojść do sytuacji, w której pracownicy od CIT nie będą nadal zajmować się PIT i VAT, ale będą mogli dostrzec zależności między CIT i VAT. Nie można wykluczyć, że wtedy mogłaby ulec zmianie priorytetyzacja celów strategicznych, choćby poprzez odejście od priorytetu zwalczania luki VAT, ale nie na rzecz zwalczania luki CIT, tylko na rzecz ograniczenia erozji bazy podatkowej. Nie sposób nie wspomnieć, że brak bieżącej dostępności do wiedzy utrudnia ocenę ryzyka stosowania modeli AI, wobec których istnieje potrzeba ciągłego walidowania i wyjaśniania. Wreszcie modele ryzyka CIT nie mogą być ustanawiane dla każdego nUS z osobna, tylko centralnie, z zapewnieniem kompatybilności z modelami ryzyka VAT, które łącznie ułatwiłyby osiągnięcie efektu synergii w ograniczeniu erozji bazy podatkowej CIT z wykorzystaniem AI.

Literatura

1. Baer, K., Barra, P., Benitez, J. C. (2025). Closing the gap: how tax administration performance shapes compliance. *IMF Working Papers*, 2025(209), 1. <https://doi.org/10.5089/9798229027076.001>
2. Bogucki, A. (2025). Ethical, legal, and socioeconomic aspects of implementing artificial intelligence in tax administration. *Acta Universitatis Lodziensis. Folia Iuridica*, 110, 19-36. <https://doi.org/10.18778/0208-6069.110.12>
3. Crivelli, E., de Mooij, R., Keen M. (2015). Base erosion, profit shifting and developing countries. *International Monetary Fund. Working Papers*, 2015(118). <https://doi.org/10.5089/9781513563831.001>
4. Engstrom, D. F., Ho, D., Sharkey, C., Cuéllar, M.-F. (2020). *Government by Algorithm: Artificial Intelligence in Federal Administrative Agencies. Report Submitted to the Administrative Conference of the United States*. NYU School of Law, Public Law Research Paper No. 20-54. <http://dx.doi.org/10.2139/ssrn.3551505>

5. European Commission (2018). *The Concept of Tax Gaps. Report II: Corporate Income Tax Gap Estimation Methodologies*, FISCALIS Tax Gap Project Group. (FPG/041).
6. Filipczak-Białkowska, A. (2019). Luka informacyjna jako czynnik wyzwalający zaciekawienie odbiorcy (na podstawie analizy nagłówków artykułów zamieszczonych w wybranych portalach internetowych). *Acta Universitatis Lodzensis. Folia Litteraria Polonica*, 48(2), 245-262. <https://doi.org/10.18778/1505-9057.48.17>
7. Gajewski, D. (2017). Luka w VAT – wyzwanie dla Unii Europejskiej. *Monitor Prawa Celnego i Podatkowego*, 12(269), 443-445.
8. Hadwick, D. (2024). Slipping through the cracks, the carve-outs for ai tax enforcement systems in the EU AI ACT. *European Papers – A Journal on Law and Integration*, 2024(9), 936955. <https://doi.org/10.15166/2499-8249/793>
9. IMF. (2025). *Digital Transformation in Tax Administration*. International Monetary Fund.
10. IRS. (2024). *Advanced Analytics Platform – Privacy Impact Assessment*. Internal Revenue Service. Pobrane z: <https://www.irs.gov/pub/irs-pia/edp-aap-pia.pdf> (dostęp: 05.06.2026).
11. Jiménez, A., Mółka, M. (2025). The use of artificial intelligence tools by tax administration on the example of Poland and Spain. *Teka Komisji Prawniczej PAN Oddział w Lublinie*, 18(1), 255-265. <https://doi.org/10.32084/tkp.9152>
12. Konopczak, K., Łożykowski, A. (2019). Kwantyfikacja zmian luki CIT: podejście ekonometryczne. *MF Working Paper Series*, 39.
13. Kuźniacki, B., Almada, M., Tyliński, K., Górski, L., Winogratska, B., Zeldenrust, R. (2022). Towards explainable artificial intelligence (Xai) in tax law: the need for a minimum legal standard. *World Tax Journal*, 14(4). <https://doi.org/10.59403/2yhh9pa>
14. Lizak, R. (2024). *Prawne aspekty neuronowego modelu zarządzania danymi w administracji federalnej Stanów Zjednoczonych z wykorzystaniem AI*. Monografie Prawnicze. C. H. Beck.
15. Loewenstein, G. (1994). The psychology of curiosity: a review and reinterpretation. *Psychological Bulletin*, 116(1), 75-98. <https://doi.org/10.1037/0033-2909.116.1.75>
16. Moore, M. H. (1995). *Creating public value: strategic management in government*. Harvard University Press.

17. NIK. (2019). *Informacja o wynikach kontroli. Agresywna optymalizacja podatkowa w zakresie CIT*. KBF.430.015.2019. Nr ewid.191/2019/P/18/010/KBF.
18. NIK. (2024). *Nadzór naczelników niewyspecjalizowanych urzędów skarbowych nad prawidłowością rozliczeń podatku dochodowego od osób prawnych*. LLU.430.001.2024. Nr ewid. 84/2024/P/23/068/LLU.
19. OECD. (2013). *Addressing base erosion and profit shifting*. OECD Publishing. <http://dx.doi.org/10.1787/9789264192744-en>.
20. OECD. (2025a). *Governing with artificial intelligence. The state of play and way forward in core government functions*. OECD Publishing. <https://doi.org/10.1787/795de142-en>.
21. OECD. (2025b). *Tax Administration Digitalisation and Digital Transformation Initiatives*. OECD Publishing, Paris. <https://doi.org/10.1787/c076d776-en>.
22. Rada Ministrów. (2026). *Uchwała nr 75 z dnia 10 lutego 2026 r. w sprawie przyjęcia strategii przeciwdziałania praniu pieniędzy oraz finansowaniu terroryzmu*. Monitor Polski, poz. 247.
23. Rozporządzenie Parlamentu Europejskiego i Rady (UE) 2024/1689 z dnia 13 czerwca 2024 r. w sprawie ustanowienia zharmonizowanych przepisów dotyczących sztucznej inteligencji oraz zmiany rozporządzeń (WE) nr 300/2008, (UE) nr 167/2013, (UE) nr 168/2013, (UE) 2018/858, (UE) 2018/1139 i (UE) 2019/2144 oraz dyrektyw 2014/90/UE, (UE) 2016/797 i (UE) 2020/1828 (akt w sprawie sztucznej inteligencji) (Tekst mający znaczenie dla EOG), PE/24/2024/REV/1, Dz.U. L, 2024/1689, 12.7.2024.
24. Sarnowski, J., Selera, P. (2020). Narzędzia informatyczne wykorzystywane w administracji skarbowej i ich wpływ na szczelność systemu podatkowego w Polsce w latach 2015-2019. *Studia BAS*, 4(64), 29-50. <https://doi.org/10.31268/StudiaBAS.2020.29>
25. Sawulski, J., Klucznik, M., Reczek, M., Rybacki, J. (2022). Luka CIT w Polsce. *Working Paper*, nr 2. Polski Instytut Ekonomiczny.
26. Shaikh, S. (2025). Balancing innovation and oversight: AI in the U.S. Treasury and IRS: a survey. *arXiv*, 2509.16294. <https://doi.org/10.48550/ARXIV.2509.16294>
27. Skuza, S., Lizak, R. (2017). Propozycje ograniczenia nadużyć w VAT z wykorzystaniem rozwiązań Business Intelligence. Autorskie propozycje wniosków

- de lege ferenda, W: D. Gajewski (red.), *Międzynarodowe unikanie opodatkowania. Wybrane zagadnienia* (s. 195-208). C.H. Beck.
28. The White House. (2020). *President's Management Agenda*. Federal Data Strategy 2020 Action Plan.
 29. Ustawa o Krajowej Administracji Skarbowej (Dz.U. z 2025 r. Nr 1131).
 30. Ustawa z dnia 1 marca 2018 r. o przeciwdziałaniu praniu pieniędzy oraz finansowaniu terroryzmu (Dz.U. z 2025 r. Nr 644).
 31. Ustawa z dnia 10 września 1999 r. Kodeks karny skarbowy (Dz.U. z 2025 r. Nr 633).
 32. Ustawa z dnia 11 marca 2004 r. o podatku od towarów i usług (Dz.U. z 2025 r. Nr 775).
 33. Ustawa z dnia 13 października 1995 r. o zasadach ewidencji i identyfikacji podatników i płatników (Dz.U. z 2025 r. Nr 237).
 34. Ustawa z dnia 15 lutego 1992 r. o podatku dochodowym od osób prawnych (Dz.U. z 2025 r. Nr 278).
 35. Ustawa z dnia 20 sierpnia 1997 r. o Krajowym Rejestrze Sądowym (Dz.U. z 2025 r. Nr 869).

Julia Grochowska¹

Studenckie Koło Naukowe Zakładu Rolnictwa, Akademia Bialska im. Jana Pawła II,
Biała Podlaska

prof. dr hab. Marcin Weiner²

Akademia Bialska im. Jana Pawła II, Biała Podlaska

ZASTOSOWANIE UCZENIA MASZYNOWEGO DO WCZESNEJ DETEKCJI STRESU U POMIDORÓW (*SOLANUM LYCOPERSICUM*) W UPRAWACH SZKLARNIOWYCH NA PODSTAWIE WYDZIELANYCH LOTNYCH ZWIĄZKÓW ORGANICZNYCH

APPLICATION OF MACHINE LEARNING FOR EARLY DETECTION OF STRESS IN TOMATO PLANTS (*SOLANUM LYCOPERSICUM*) IN GREENHOUSE CULTIVATION BASED ON EMITTED VOLATILE ORGANIC COMPOUNDS

Streszczenie

Wobec rosnących wymagań dotyczących produkcji rolniczej oraz potrzeby ograniczenia stosowania chemicznych środków ochrony roślin, coraz większego znaczenia

¹ <https://orcid.org/0009-0006-9441-4002>, e-mail: grochowska23375@stud.akademiabialska.pl

² <https://orcid.org/0000-0001-9288-0823>

Grochowska, J., Weiner, M. (2026). Zastosowanie uczenia maszynowego do wczesnej detekcji stresu u pomidorów (*Solanum lycopersicum*) w uprawach szklarniowych na podstawie wydzielanych lotnych związków organicznych. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 96-118). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_6

nabierają metody umożliwiające wczesne i precyzyjne wykrywanie stresu u roślin. Rośliny pomidora (*Solanum lycopersicum*) emitują charakterystyczne zestawy lotnych związków organicznych (LZO), których profil ulega zmianie pod wpływem różnych bodźców biotycznych i abiotycznych. W prezentowanej pracy, z wykorzystaniem nadzorowanego uczenia maszynowego, podjęto próbę weryfikacji wstępnej hipotezy mówiącej, że zmiany w emisji LZO mogą odzwierciedlać działanie odmiennych czynników stresowych. Takie podejście mogłoby znaleźć zastosowanie w systemach wczesnego wykrywania zagrożeń wpływających na wielkość i jakość plonu, opartych na sieciach czujników oraz algorytmach przetwarzających i interpretujących dane. Rozwiązania tego typu szczególnie dobrze wpisują się w warunki upraw szklarniowych, gdzie łatwiej o kontrolę środowiska i wiarygodny odczyt sygnałów. W oparciu o dane z publikacji naukowych zbudowano niewielki model drzewa decyzyjnego w ramach strategii *Proof-of-Concept*, którego działanie potwierdziło, że zmienność emisji wybranych grup związków lotnych może stanowić podstawę do rozróżniania analizowanych kategorii stresu, pomimo istotnych ograniczeń wynikających ze zróżnicowania źródeł i protokołów badawczych.

Słowa kluczowe: lotne związki organiczne, stres roślin, uczenie maszynowe

Abstract

In response to increasing demands on agricultural production and the need to reduce the use of chemical plant protection products, methods enabling the early and accurate detection of plant stress are gaining importance. Tomato plants (*Solanum lycopersicum*) emit characteristic sets of volatile organic compounds (VOCs), the composition of which changes under the influence of various biotic and abiotic factors. In this study, supervised machine learning was used to examine the preliminary hypothesis that alterations in VOC emission profiles may reflect the action of different stressors. Such an approach could be applied in early warning systems designed to detect threats that reduce yield quantity and quality, relying on sensor networks and data-processing systems utilising artificial intelligence algorithms. These solutions may be particularly useful in greenhouse cultivation, where controlled conditions allow for more reliable signal detection. Based on experimental data reported in scientific publications, a small decision-tree model was developed as a Proof-of-Concept. Its performance indicated that variations in the emission of selected VOCs may provide a basis for distinguishing between the stress categories considered, despite methodological limitations resulting from the heterogeneity of available studies and protocols.

Keywords: volatile organic compounds, plant stress, machine learning

Wstęp

W kontekście rosnącego światowego zapotrzebowania na żywność, ściśle powiązanego ze wzrostem globalnej populacji i poziomu wymagań konsumentskich, współczesne rolnictwo mierzy się z istotnymi wyzwaniami dotyczącymi bezpieczeństwa żywnościowego. Coraz wyższe oczekiwania rynku względem produkcji rolnej nasilają problem nierozważnego stosowania środków ochrony roślin i nawozów sztucznych w rolnictwie, niosąc poważne konsekwencje dla zdrowia publicznego (Gargiulo i in., 2025). Dzieje się tak głównie dlatego, że w rolnictwie przemysłowym najszybszą i najłatwiej dostępną metodą minimalizacji strat jest stosowanie chemii rolniczej. Pozwala ona na możliwie najszybsze eliminowanie przyczyn lub skutków stresów roślin, warunkowanych zarówno przez czynniki biotyczne, jak i abiotyczne. Gospodarstwa przemysłowe nastawione są na maksymalizację wydajności i minimalizację kosztów jednostkowych, stąd zamiast prowadzenia skrupulatnego monitoringu stanu roślin i doboru zabiegów w sposób ściśle wynikających z uzasadnionych potrzeb, wielu producentów rolnych decyduje się na stosowanie stałych, sprawdzonych w swojej praktyce procedur opartych na aplikacji nieobojętnych dla zdrowia człowieka i środowiska środków chemicznych (Deguine i in., 2021).

Kompromisowym rozwiązaniem jest prowadzenie uprawy w sposób integrowany. Przenosi on punkt ciężkości z działań szablonowych i reaktywnych na odpowiedzialną prewencję oraz interwencje celowane, uzależnione od faktycznej presji agrofagów. Nadrzędnym celem tego silnie promowanego przez Unię Europejską systemu jest zachowanie równowagi pomiędzy wysokością plonów, zdrowiem roślin a ochroną środowiska. W 2009 r. dyrektywa 2009/128/WE zobowiązała państwa członkowskie do wspierania rolników w przechodzeniu na integrowaną ochronę roślin (Dyrektywa 2009/128/WE, 2009). W wyniku implementacji przepisów unijnych od 1 stycznia 2014 r. w Polsce stosowanie integrowanej ochrony roślin stało się obowiązkowe dla profesjonalnych użytkowników środków ochrony roślin. Za użytkownika profesjonalnego uznaje się osobę fizyczną, która stosuje te preparaty w celach innych niż własne, niezarobkowe potrzeby, a więc przede wszystkim w ramach działalności gospodarczej lub zawodowej, w tym w rolnictwie i leśnictwie (Ustawa z dnia 8 marca 2013 r. o środkach ochrony roślin). Danego pestycydu używamy tylko wtedy, gdy monitoring (obserwacje, pułapki, progi ekonomicznej szkodliwości) jednoznacznie

wskaże, że populacja agrofaga osiągnęła poziom, przy którym spodziewane straty gospodarcze przewyższą koszt zabiegu. Odejście od powszechnego stosowania środków ochrony roślin o szerokim spektrum działania (ogólnobójczych) na rzecz celowanych i precyzyjnych zabiegów nie tylko minimalizuje negatywny wpływ na środowisko i organizmy niebędące celem, ale także zapobiega rozwojowi odporności u patogenów i szkodników, jednocześnie znacząco redukując obciążenie żywnościowe pozostałościami chemicznymi.

W praktyce wdrożenie tych zasad napotyka jednak na wyzwania, zwłaszcza w przypadku gospodarstw wielkopowierzchniowych, gdzie prowadzenie monitoringu stanu plantacji w czasie rzeczywistym jest niezwykle trudne (Deguine i in., 2021). Kompleksowy nadzór wymagałby bowiem jednoczesnego kontrolowania abiotycznych warunków siedliskowych oraz obserwacji pod kątem występowania licznych i zróżnicowanych grup organizmów szkodliwych. Należą do nich zarówno mikroorganizmy (bakterie, wirusy, grzyby), jak i bezkręgowce, w tym owady, nicienie czy roztocza. Wśród tych grup klasyfikuje się ogromną liczbę odmiennych gatunków agrofagów, których prawidłowa identyfikacja wymaga zaangażowania, wiedzy i doświadczenia (Gougherty, Davies, 2021).

Istnieje jednak możliwość wykorzystania współczesnej wiedzy o biologii roślin uprawnych do opracowywania strategii detekcji subtelnych sygnałów stresu, które są przez nie manifestowane już na jego bardzo wczesnym etapie, a nawet w ramach mechanizmów preadaptacyjnych. Zaawansowane czujniki są w stanie rejestrować różnego rodzaju sygnały manifestowane przez rośliny, a zintegrowane z nimi systemy informatyczne, często oparte o sztuczną inteligencję, przekształcać je w informacje czytelne dla człowieka. W takich systemach zastosowane mogą być przykładowo matryce sensorów (tzw. elektroniczne nosy), które dostarczają molekularne „odciski palców” emitowanych przez rośliny lotnych związków organicznych (LZO) (Gan i in., 2023). Są to wyspecjalizowane metabolity o małej masie cząsteczkowej (50-200 Da) i wysokiej prężności par w temperaturze otoczenia, co umożliwia im łatwe przechodzenie do fazy gazowej i dyfuzję w atmosferze (Peñuelas, Llusia, 2001). Odgrywają kluczową rolę w komunikacji roślin i sygnalizacji obronnej. Emisja LZO wzrasta w warunkach stresowych, takich jak uszkodzenia mechaniczne, atak owadów czy infekcja. Przykładowo, rutynowe zabiegi pielęgnacyjne, jak usuwanie starych liści, zwiększają emisję n-heksanal i (E)-2-heksenal (Gargiulo

i in., 2025). Możliwość nieinwazyjnego „podsluchiwania” chemicznego języka roślin, za pomocą którego komunikują one stres, otwiera drogę do opracowania nowych technologii pozwalających na kontrolę stanu roślin w stanie rzeczywistym, a co za tym idzie: natychmiastowych, celowanych interwencji.

O ile monitoring i analiza profilu LZO w skali uprawy polowej są bardzo trudne, o tyle kontrolowane środowisko szklarni stwarza idealne warunki do wdrożenia takich rozwiązań, przykładowo w uprawach pomidora (*Solanum lycopersicum* L.). Jest to roślina o wysokiej wartości ekonomicznej i stanowi kluczowe źródło pożywienia na świecie (Martina i in., 2021). Jednocześnie jest to ważny organizm modelowy w badaniach podstawowych i stosowanych. Dla pełnego wykorzystania potencjału rozwijających się technologii rejestrowania LZO duże znaczenie ma odpowiedź na pytanie jakie związki powinniśmy wykrywać w uprawach w celu identyfikacji rodzaju stresu roślin. Czy większe znaczenie będzie mieć rozpoznawanie pojedynczych markerów, pełnych profili emisji, czy może wzorców wydzielania poszczególnych związków w okresach czasowych? W literaturze dostępne są informacje dotyczące różnic w składzie LZO uwalnianych pod wpływem odmiennych bodźców biotycznych i abiotycznych działających na pomidory. Różnice te warunkowane są uruchamianiem osobnych ścieżek obronnych i sygnałowych, co rodzi potencjał do ustalenia jakich specyficznych emisji powinniśmy się spodziewać w trakcie wystąpienia danego zagrożenia, niezależnie od tego, czy będzie ono wywołane żerowaniem konkretnego owada, zasoleniem gleby, nieodpowiednią temperaturą, czy rozwijającą się infekcją grzybową. To właśnie zagadnienie stanowi główny problem badawczy oraz punkt wyjścia niniejszej pracy, której celem było zastosowanie nadzorowanego uczenia maszynowego do budowy modelu drzewa decyzyjnego klasyfikującego rodzaj stresu pomidora zwyczajnego na podstawie wzrostu emisji poszczególnych związków lotnych.

Materiał i metody

W celu opracowania prototypowego modelu dokonano przeglądu literatury naukowej, na podstawie której stworzono bazę danych. Zidentyfikowano i przeanalizowano 33 publikacje badawcze dokumentujące profile emisji LZO u roślin pomidora poddanych różnym rodzajom stresu. Zebrane dane podzielone na 54 przypadki uporządkowano w formie ustrukturyzowanej macierzy

danych. W przyjętym schemacie każdy wiersz odpowiadał pojedynczemu eksperymentowi, a kolumny opisane były przez 186 zmiennych, reprezentujących poszczególne związki lotne. Aby uchwycić zmianę emisji, przyjęto system binarny, gdzie wartość „1” rejestrowała zwiększoną emisję danego LZO w porównaniu do roślin kontrolnych, natomiast wartość „0” obejmowała zarówno brak wzrostu emisji danego LZO, jak i brak jego raportowania w analizowanej publikacji. Podejście to upraszczało integrację danych literaturowych, jednak może prowadzić do niedoszacowania znaczenia związków rzadziej raportowanych. Wykorzystanie modelu drzewa decyzyjnego w prezentowanym badaniu zostało podyktowane jego wysoką interpretowalnością, która pozwala na prześledzenie ścieżki decyzyjnej i identyfikację konkretnych związków LZO o największym znaczeniu diagnostycznym dla danego typu stresu oraz odpornością na nieistotne zmienne. Dodatkowo, przy stosunkowo niewielkim zbiorze danych wejściowych, drzewa decyzyjne są mniej podatne na nadmierne dopasowanie w porównaniu do bardziej złożonych modeli (np. sieci neuronowych) i skutecznie radzą sobie z identyfikacją nieliniarnych zależności w danych (Liu i in., 2004). Dane wejściowe opisano w Tabelach 1 i 2.

Tabela 1. Dane wejściowe: czynniki biotyczne

Odniesienie do literatury	Czynnik wywołujący stres (gatunek)	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
López-Gresa i in., 2017	<i>Pseudomonas syringae</i> DC3000 pv. tomato.	bakteria	salicylan etylu, salicylan metylu, salicylaldehyd, α -pinen, α -felandren, β -felandren, limonen, p-cymen
Arafa i in., 2022	<i>Phytophthora infestans</i> , gatunek grzybobodobny wywołujący zarazę ziemniaka	legniowiec grzybobodobny	3,4,5,7-tetrametoksyflawon, skopoletyna, nabilon, α -tokoferol
Jansen i in., 2009	<i>Botrytis cinerea</i> , gronowiec szary, wywołujący chorobę szara pleśń	grzyb	α -pinen, α -felandren, β -felandren, limonen, 2-karen, 1-penten-3-ol, (Z)-heks-3-enal, (Z)-3-heksen-1-ol, (E)-heks-2-enal, octan (Z)-3-heksen-1-ylu
Hernández-Aparicio i in., 2021	<i>Fusarium oxysporum</i> , wywołujący kompleks chorób nazywanych zgorzelami lub fuzariozami	grzyb	salicylan etylu, salicylan metylu, pentan-2-on, 2-nonenal, heksan-2-on, heptan-2-on, heptan-3-on, but-3-en-2-on, butanal, butan-2-on
Nawrocka i in., 2022	<i>Botrytis cinerea</i> , gronowiec szary, wywołujący chorobę szara pleśń	grzyb	salicylan etylu, salicylan metylu, fenol, heksanal, 4-metyloheksan-3-ol, 2-etyloheksan-1-ol, heks-2-en-1-ol, 1-(2-hydroksyfenyl)etanon, (E)-heks-2-enal, heksan-1-ol, 2-metylobenzaldehyd, acetofenon, salicylan hept-4-en-2-ylu, 2-metylofenol
Kasal i in., 2015	<i>Botrytis cinerea</i> , gronowiec szary, wywołujący chorobę szara pleśń	grzyb	salicylan metylu, β -kariofilen, (Z)-3-heksen-1-ol, (E)- β -ocymen, α -kopaen, walencen, aristolen, α -terpinen, izomaślan (Z)-3-heksenyli, δ -elemen, β -selinen
Kasal i in., 2015	<i>Oidium neolycopersici</i> , grzyb wywołujący chorobę mączniak prawdziwy pomidora	grzyb	β -kariofilen, (Z)-3-heksen-1-ol, α -kopaen, α -terpinen
Tomescu i in., 2017	<i>Botrytis cinerea</i> , gronowiec szary, wywołujący chorobę szara pleśń	grzyb	salicylan metylu, (Z)-3-heksen-1-ol, α -terpinen, heksanal, 2-hydroksyacetofenon, (E)-heks-2-enal

Odniesienie do literatury	Czynnik wywołujący stres (gatunek)	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
Kasal-Slavik i in., 2017	<i>Botrytis cinerea</i> , gronowiec szary, wywołujący chorobę szara pleśń	grzyb	salicylan metylu, β -felandren, limonen, (Z)-heks-3-enal, (Z)-heks-3-en-1-ol, propanian (Z)-heks-3-en-1-ylu, α -kopaen, β -ocymen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT), heksanal, (E)-2-heksenal, (E, E)-2, 4-heksadienal, 2-penten-1-ol, masłan (Z)-heks-3-en-1-ylu, pentanian (Z)-heks-3-en-1-ylu, izomasłan (Z)-heks-3-en-1-ylu
Kasal-Slavik i in., 2017	<i>Oidium neolycopersici</i> , grzyb wywołujący chorobę mączniak prawdziwy pomidora	grzyb	α -kopaen
Ghosh i in., 2022	TYLCV, wirus żółtej kędzierzawości liści pomidora	wirus	gwajakol, 1,3-dimetylobenzen, 2-dimetoksybenzen, fenol, 1-oktanol, kwas 9-heksadekenowy, palmitooleinian metylu
Spanò i in., 2023	wirus PVY (Y ziemniaka)	wirus	salicylan metylu, β -linalol, 1-penten-3-ol, (E)-3-heksen-1-ol, (Z)-3-heksen-1-ol, alkohol benzylovowy, α -kopaen, gwajakol, 3-pentanon, (E)-2 heksen-1 ol, α -terpinen, benzaldehid, heksanal, (E)-heks-2-enal, heksan-1-ol, (E,E)-heksa-2,4-dienal, heks-3-enal, octan heksen-1-ylu, 2-metylo-pentan-1-ol, (Z)-pent-2-en-1-ol, pent-1-en-3-ol, pentan-1-ol, alkohol benzylovowy, 2-fenylloctanol, nonanian metylu, (E)-2-heksenian metylu, 6-metylo-5-hepten-2-on, 2-etylofuran, 2-pentylofuran, o-gwajakol
Sun i in., 2010	<i>Meloidogyne incognita</i> , nicienie wywołujący chorobę potłudniowy guzaki korzeniowy	nicień	α -pinen, α -felandren, β -felandren, karweol, p-cymen, β -mircen, kamfen
Cui i in., 2019	<i>Myzus persicae</i> , mszyca brzo-skwinio-ziemniaczana	owad wysysający sok	α -pinen, α -felandren, β -linalol, karweol, kariofilen
Silva i in., 2017	<i>Bemisia tabaci</i> , mączlik ostroskrzydły	owady wysysający sok	salicylan metylu, pent-1-en-3-ol, pentan-3-ol, (E)-4-oksoheks-2-enal, α -kopaen, β -kopaen, walencen, aristolochen, (Z)-pent-2-en-1-ol, konofityna, β -cyklocytral

Odniesienie do literatury	Czynnik wywołujący stres (gatunek)	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
Ángeles i in., 2012	<i>Trialeurodes vaporariorum</i> , mączlik szklarniowy	owad wysysający sok	salicylan metylu, α -pinen, β -kariofilen, α -humulen, α -gurjunen, izolenden, dekan, (E/Z)- β -ocymen, tlenek kariofilenu, α -muurolen, aromadendren, δ -kadinen, gerkakren D, aristolen,
Meijer i in., 2023	<i>Tetranychus urticae</i> , przędziorek chmielowiec	roztocze wysysający sok	linalol, (Z)-heks-3-en-1-ol, (E)- β -jonon
Ghosh i in., 2022	<i>Bemisia tabaci</i> , mączlik ostroskrzydły	owad wysysający sok	gwajakol, 1-oktanol, kwas 7,10,13-heksadekatrienowy
Islam i in., 2017	<i>Bemisia tabaci</i> , mączlik ostroskrzydły	owad wysysający sok	β -pinen, β -kariofilen, β -felandren, p-cymen, α -kopaen, (+)-4-karen, α -terpinen
Kasal i in., 2015	<i>Myzus persicae</i> , mszyca brzo-skwinioowo-ziemniaczana	owad wysysający sok	salicylan metylu, α -terpinen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT)
Kasal i in., 2015	<i>Trialeurodes vaporariorum</i> , mączlik szklarniowy	owad wysysający sok	(Z)-3-heksen-1-ol, α -terpinen
Tomescu i in., 2017	<i>Trialeurodes vaporariorum</i> , mączlik szklarniowy	owad wysysający sok	salicylan metylu, β -kariofilen, α -kopaen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT)
Tomescu i in., 2017	<i>Myzus persicae</i> , mszyca brzo-skwinioowo-ziemniaczana	owad wysysający sok	salicylan metylu, α -terpinen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT)
Kasal-Slavik i in., 2017	<i>Myzus persicae</i> , mszyca brzo-skwinioowo-ziemniaczana	owad wysysający sok	salicylan metylu
Silva i in., 2017	<i>Tuta absoluta</i> , skośnik pomidorowy	owad gryzący	salicylan metylu, β -kariofilen, linalol, α -humulen, pent-1-en-3-ol, pentan-3-ol, (E)-pent-2-enal, (Z)-heks-3-en-1-ol, octan (Z)-heks-3-en-1-ylu, propionian (Z)-heks-3-en-1-ylu, (Z)-jajmon, alkohol benzylowy, indol, antranilan metylu, maślan benzylu, eugenol, (E)- β -ocymen, (E)-DMNT, krotonian (Z)-heks-3-en-1-ylu, angelan (Z)-heks-3-en-1-ylu, octan (Z)-pent-2-en-1-ylu, maślan (Z)-pent-2-en-1-ylu, α -humulen

Odniesienie do literatury	Czynnik wywołujący stres (gatunek)	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
D'Esposito i in., 2023	<i>Tuta absoluta</i> , skośnik pomidorowy	owad gryzący	salicylan metylu, ocymen, δ -3-karen, γ -terpinen
Vescio i in., 2022	<i>Tuta absoluta</i> , skośnik pomidorowy	owad gryzący	β -pinen, α -pinen, β -kariofilen, β -felandren, α -kopaen, (E)-2-heksen-1-ol, (2E)-2-heksen-1-yl propionian, propionian heksylu, (+)-4-karen, terpinolen
Lin i in., 2022	<i>Helicoverpa zea</i>	owad gryzący	salicylan etylu, α -pinen, α -kariofilen, β -kariofilen, alfa-humulen, (Z)-3-heksen-1-ol, (Z)-jasmon, indol, α -kopaen, alloocymen, β -ocymen, b-mircen, α -humulen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT), springen, 6,9-gwajadien
Chen i in., 2021	<i>Tuta absoluta</i> , skośnik pomidorowy	owad gryzący	(E)-heks-3-en-1-olowy (E)-2-metylobut-2-enian, (E)-heks-3-en-1-ol, (Z)-hex-3-en-1-ol, β -cyklocytral, 2-pentylfuran, 2,6-dimetylocykloheksan-1-on, β -izo-metylojonon, β -safranal, nerolidol, kwas but-2-enowy, 2-etylobenzaldehyd, 2,6-dimetylocykloheksanol, 1-okten-3-ol
Maes i in., 2003	<i>Spodoptera littoralis</i> , sówka bawełnowka egipska	owad gryzący	β -pinen, δ -kariofilen, β -kariofilen, β -linalol, indol
Zebelo i in., 2014	<i>Spodoptera exigua</i> , światłówka naziemnica	owad gryzący	salicylan metylu, γ -terpinen, (E)- β -kariofilen, β -linalol, alfa-humulen, (Z)-3-heksen-1-ol, octan (Z)-heks-3-en-1-ylu, γ -terpinen, (E)-2-heksenal, δ -elemen, β -elemen, (Z)-heks-2-en-1-ol, 3-oktanol, nonanal, dekanal
Tomescu i in., 2017	<i>Spodoptera littoralis</i> , sówka bawełnowka egipska	owad gryzący	β -pinen, β -kariofilen, β -linalol, (Z)-heks-3-enal, indol, (E)-heks-2-enal, (Z)-heks-2-en-1-ol, octan (Z)-heks-3-en-ylu
Kergunteuil i in., 2021	<i>Tuta absoluta</i> , skośnik pomidorowy	owad gryzący	α -pinen, β -felandren, 2-karen
Raghava i in., 2010	<i>Spodoptera litura</i> , sówka bawełnowka azjatycka	owad gryzący	α -pinen, kariofilen, alfa-humulen, ocymen, b-mircen, terpinolen, karen, 3-metylobutanal

Odniesienie do literatury	Czynnik wywołujący stres (gatunek)	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
Farag i in., 2002	<i>Manduca sexta</i> , zawisak tytoniowy	owad gryzący	salicylan metylu, β -pinen, α -pinen, β -kariofilen, β -felandren, α -felandren, alfa-humulen, 2-karen, (Z)-heks-3-enal, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT), heksanal, (E)-heks-2-enal, δ -elemen, (Z)-heks-2-en-1-ol, β -pinen, α -pinen, β -kariofilen, α -humulen, ocymen, α -terpinen, δ -elemen, octanian linalylu, sabinen
Disi i in., 2017	<i>Spodoptera exigua</i> , światłówka naziemnica	owad gryzący	

Tabela 2. Dane wejściowe: czynniki abiotyczne

Odniesienie do literatury	Czynnik wywołujący stres	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
Nagalingam i in., 2022	wysoka temperatura	stres termiczny	salicylan metylu, α -pinen, α -felandren, β -felandren, limonen, 2-karen, α -terpinen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT)
Copolovici i in., 2012	szok zimna	stres termiczny	α -pinen, α -felandren, β -kariofilen, β -felandren, 2-karen, (Z)-3-heksen-1-ol, β -ocymen, (E)-heks-2-enal, heksan-1-ol, β -elemen, heksa-1,4-dienal
Vescio i in., 2022	susza	stres wodny	α -humulen, α -terpinen, δ -terpinen
Pagadala Damodaram i in., 2021	stres wodny	stres wodny	α -pinen, β -felandren, (+)-4-karen, terpinolen, m-cymen, β -tujen
Pagadala Damodaram i in., 2021	umiarkowany stres wodny	stres wodny	etylobenzaldehyd, heksan-2,5-diol, 1-fenyl-1-buten, 4-(prop-2-enyl)fenol, dodekan, kwas dekanowy, fitan, 2,6,10-trimetylotetradekan, γ -butylo- γ -butyrolakton
Kasal i in., 2015	susza	stres wodny	(Z)-3-heksen-1-ol, β -ocymen, α -terpinen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT)
Tomescu i in., 2017	krytyczna susza	stres wodny	(Z)-3-heksen-1-ol

Odniesienie do literatury	Czynnik wywołujący stres	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
Maes i in., 2003	ciągłe oświetlenie	stres świetlny	β -kopaen
Tomescu i in., 2017	ciągłe oświetlenie	stres świetlny	β -kopaen
Sun i in., 2010	podwyższony poziom CO ₂	stres gazowy	α -pinen, karweol, p-cymen
Kasal i in., 2015	ekspozycja na ozon	stres gazowy	salicylan metylu, (E)- β -ocymen, izomaślan (Z)-3-heksenylu
Mina i in., 2010	ekspozycja na ozon	stres gazowy	izopren
Tomescu i in., 2017	ekspozycja na ozon	stres gazowy	izopren
Vescio i in., 2022	niedobór azotu	stres odżywczy	α -humulen, α -terpinen, δ -terpinen
Kergunteuil i in., 2021	niedobór azotu	stres odżywczy	salicylan metylu
Tomescu i in., 2017	zasolenie gleby	stres chemiczny	β -felandren, 2-karen, (Z)-3-heksen-1-ol
Zhang i in., 2018	zasolenie gleby (NaCl)	stres chemiczny	β -felandren, kariofilen, (-)-kopaen, mircen, (+)-4-karen, terpinolen, δ -elemen, geranyloaceton, α -kubeben, kwas heksadekanowy, kwas oktadekanowy
Vehar i in., 2025	zanieczyszczenia w roztworze odżywczym w uprawie hydroponicznej (CECs)	stres chemiczny	octanian metylu, ftalan dietylu, benzenonitryl, kwas heptanowy, nonanediol dimetylu

Wyniki

Z analizy pozyskanych artykułów naukowych wyodrębniono przypadki stresów roślinnych, które sklasyfikowano według rodzaju czynników wywołujących je na stresy biotyczne i abiotyczne. Stres biotyczny obejmował czynniki powodowane przez organizmy żywe, w tym bakterie *Pseudomonas syringae* pv. *tomato*, patogeny grzybowe: *Botrytis cinerea* (gatunek wywołujący chorobę szara pleśń) *Fusarium oxysporum* (wywołujący fuzariozę), *Oidium neolycopersici* (wywołujący chorobę mączniak prawdziwy), *Phytophthora infestans* (wywołujący zarazę ziemniaka), wirusy: wirus żółtej kędzierzawości liści pomidora (TYLCV), wirus Y ziemniaka, nicien *Meloidogyne incognita* (wywołujący chorobę guzak korzeni), owady gryzące i żujące, takie jak skośnik pomidorowy (*Tuta absoluta*), światłówka naziemnica (*Spodoptera exigua*), *Helicoverpa zea*, zawisak tytoniowy (*Manduca sexta*), sówka bawełnówka azjatycka (*Spodoptera litura*), sówka bawełnówka egipska (*Spodoptera littoralis*), a także owady i roztocza ssące i wysysające sok, m.in. mszyca brzoskwińowo-ziemniaczana (*Myzus persicae*), mączlik ostroskrzydły (*Bemisia tabaci*), mączlik szklarniowy (*Trialeurodes vaporariorum*) oraz przedziorek chmielowiec (*Tetranychus urticae*). Stresy abiotyczne obejmowały czynniki środowiskowe, w tym stres wodny, stres termiczny, a także stresy świetlne, gazowe, chemiczne i odżywcze, jak podwyższony CO₂, zasolenie gleby czy niedobór azotu.

Na etapie wstępnej, eksploracyjnej analizy uzyskanego zbioru danych zidentyfikowano pewne ograniczenia związane ze zbyt niską reprezentacją części przypadków oraz dużą niespójnością profili emisji LZO nawet w ramach tej samej kategorii stresu. Źródłem tego zróżnicowania jest natura analizy, każda z 33 prac stosowała inne protokoły badawcze (m.in. definiując inaczej intensywność i czas trwania stresu). Dla algorytmu uczenia maszynowego taka niejednorodność danych stanowi wyzwanie dla procesu uczenia modelu. Drugim wyzwaniem był problem niskiej specyficzności sygnału i nakładania się profili LZO pomiędzy różnymi klasami stresu. Wobec zidentyfikowanych wyzwań, odstąpiono od próby budowy „uniwersalnego” klasyfikatora. Zamiast tego, przyjęto strategię *Proof-of-Concept* (PoC). W tym celu ograniczono zbiór danych do 27 przypadków z 22 prac badawczych w ramach trzech kategorii stresu, które z perspektywy przemysłowej są kluczowe, a z perspektywy biologicznej- zakładają odmienne ścieżki metaboliczne: Owady i roztocza ssące/

wysysające sok, owady gryzące/żujące ($n=12$), stres termiczny ($n=4$). Dodatkowo, usunięto z dalszej analizy wszystkie związki, które nie pojawiły się w żadnym z uwzględnionych przypadków stresu, pozostawiając 104 związki lotne.


Budowa modelu

Do budowy i walidacji modelu klasyfikacyjnego wykorzystano język programowania Python w interaktywnym środowisku Jupyter Notebook, które umożliwiło elastyczne prowadzenie analiz oraz bieżącą wizualizację wyników (Kluyver i in., 2016). Kluczowe etapy pracy opierały się na bibliotekach open-source szeroko stosowanych w analizie danych i uczeniu maszynowym. Pandas (The pandas development team, 2025) do przygotowania zbioru wejściowego, tj. wczytywania, oczyszczania oraz manipulacji danymi. Scikit-learn (Pedregosa i in., 2011) do budowy modelu klasyfikacyjnego, wykorzystano m.in. funkcję `train_test_split` do stratyfikowanego podziału danych na zbiór treningowy i testowy, przy czym proporcja wynosiła 70% danych do treningu i 30% do testowania, co zapewniło odpowiednią równowagę między możliwością nauczania modelu a rzetelną oceną jego generalizacji. Ponadto wykorzystano `DecisionTreeClassifier` do trenowania drzewa decyzyjnego oraz `accuracy_score` i `confusion_matrix` do oceny jakości predykcji na zbiorze testowym. Do wizualizacji wyników, w szczególności do przedstawienia końcowej struktury wytrenowanego drzewa decyzyjnego, wykorzystano bibliotekę Matplotlib (Hunter, 2007) w połączeniu z funkcją `plot_tree` dostępną w module `sklearn.tree`, co pozwoliło przedstawić model w formie intuicyjnego i czytelnego diagramu.

Implementacja i wyniki modelu klasyfikacyjnego

W procesie klasyfikacji badanych stresorów kluczowy atrybut decyzyjny stanowi α -humulen. Wzrost emisji tego związku, analizowany w węźle korzeniowym drzewa, identyfikowany jest jako predyktor o zerowej nieczystości (wskaźnik Giniego = 0,0) dla kategorii „Owady gryzące/żujące”. Oznacza to, że w oparciu o analizowane dane, sam fakt indukcji tego seskwiterpenu,

jest warunkiem wystarczającym do jednoznacznej klasyfikacji. Alternatywnie, klasa „Owady gryzące/żujące” może być również identyfikowana poprzez wzrost emisji δ -kariofilenu. Sygnał ten ujawnia się w ścieżce decyzyjnej, gdy nie stwierdza się indukcji ani α -humulenu, ani β -felandrenu, reprezentując zatem wtórny, alternatywny marker żerowania, również oparty na biosyntezie seskwiterpenów. Klasa „Stres cieplny/termiczny” definiowana jest przez jednoczesny wzrost emisji dwóch monoterpenów: β -felandrenu oraz α -felandrenu. Ta specyficzna koincydencja wskazuje na prawdopodobną, zsynchronizowaną aktywację szlaków biosyntezy tych monoterpenów w plastydach, stanowiącą odpowiedź na stres cieplny/termiczny. Z kolei klasa „Owady i roztocza ssące/wysysające sok” jest najczęściej klasyfikowana w sytuacji braku wzrostu któregośkolwiek z wyselekcjonowanych przez model związków markerowych (Rysunek 1).



Rysunek 1. Wizualizacja opracowanego drzewa decyzyjnego

Źródło: opracowanie własne.

Ewaluacja skuteczności klasyfikacji

Skuteczność modelu poddano ocenie na wcześniej niewidzianym zbiorze testowym, zachowując zasadę stratyfikacji. Osiągnięty poziom trafności wyniósł 55,56%. Należy podkreślić, że wynik ten jest istotnie wyższy od teoretycznego progu losowego, który dla problemu trójklasowego wynosi 33,3%. Różnica ta, sięgająca ponad 22 punkty procentowe, stanowi przesłankę, że

model nie dokonuje klasyfikacji w sposób czysto przypadkowy, lecz jest w stanie wychwycić i interpretować rzeczywiste, choć subtelne, wzorce w danych chemicznych.

Dyskusja

Analiza wytrenowanego modelu ujawniła, że kluczowym węzłem w hierarchicznej strukturze decyzyjnej, umożliwiającej wstępną identyfikację markerów, jest α -humulen. Jego podwyższona emisja jest tu charakterystyczna dla stresu indukowanego przez owady gryzące/ żujące, co znajduje uzasadnienie w literaturze przedmiotu. Zwiększona emisja α -humulenu w odpowiedzi na żerowanie owadów gryzących jest elementem indukowanej odpowiedzi obronnej roślin, często obserwowanym u pomidora. Mechanizm ten rozpoczyna się od uszkodzenia tkanek i kontaktu z elitorami obecnymi w płynach dostających się do rośliny podczas żerowania, do których należą m.in. wydzieliny z brzusznych gruczołów wywracanych gąsienic *Spodoptera exigua*, które znacząco zwiększają produkcję i emisję pewnych związków lotnych, w tym α -humulenu (Kutty, Mishra, 2023).

Model w procesie decyzyjnym uwzględnił również inne związki terpenowe, takie jak β -felandren, δ -kariofilen oraz α -felandren. Zostały one wykorzystane jako dodatkowe sygnały różnicujące, co sugeruje, że w dostępnych danych występowały pewne regularności w zwiększeniu ich emisji, które algorytm uznał za pomocne przy rozróżnianiu typów stresu. Należy jednak podkreślić, iż wybór tych konkretnych związków przez model nie musi odzwierciedlać ich fundamentalnego znaczenia jako biomarkerów, a raczej, że ich zmienność była wystarczająco informatywna, by wspierać proces klasyfikacji.

Uzyskana trafność na poziomie 55,56%, choć nieosiągająca wartości optymalnych dla bardzo dobrej klasyfikacji, musi być interpretowana w kontekście inherentnych wyzwań związanych z analizą danych biologicznych. Czynniki takie jak zróżnicowanie indywidualne między replikami roślinnymi, potencjalne nakładanie się szlaków sygnalizacyjnych w odpowiedzi na różne typy stresorów oraz bardzo ograniczona liczebność zbioru danych (która zwiększa ryzyko nadmiernego dopasowania modelu oraz ogranicza jego zdolność do generalizacji) znacząco utrudniają zadanie modelu. Ograniczeniem pracy jest również brak standaryzacji metod pomiarowych w analizowanych

publikacjach, co mogło wpływać na wykrywalność określonych związków. Biorąc pod uwagę te ograniczenia, fakt, że model był w stanie w ogóle wykroczyć poza próg losowości i zidentyfikować istotne biomarkery, świadczy o potencjale diagnostycznym zastosowanej metody. Dalszy rozwój badań wymaga przede wszystkim stworzenia spójnego korpusu danych pozyskanego w warunkach kontrolowanych, co pozwoli na pełniejszą i bardziej wiarygodną ocenę możliwości modelu. Kluczowe byłoby również oparcie analiz na dokładnych pomiarach stężeń, dzięki którym możliwe stanie się precyzyjniejsze uchwycenie różnic biologicznych między obserwowanymi stanami. Uzupełnieniem tych działań powinna być eksploracja bardziej zaawansowanych architektur uczenia maszynowego, mogących skuteczniej wydobywać subtelne wzorce związane ze stresem.

Wnioski

Przeprowadzone badanie potwierdziło, że profil emisji LZO może stanowić wartościowe źródło informacji diagnostycznej w kontekście wczesnej detekcji stresu u pomidorów w środowisku szklarniowym. Pomimo znaczącej heterogeniczności danych literaturowych i ograniczonej liczby spójnych obserwacji, opracowany prototypowy model drzewa decyzyjnego wykazał zdolność wychwytywania powtarzalnych wzorców charakterystycznych dla różnych kategorii stresu. Uzyskany wynik klasyfikacji na poziomie 55,56%, znacznie wyższym niż próg losowy, wskazuje, że nawet uproszczone, binarne odwzorowanie sygnałów pozwala modelowi identyfikować pewne związki o znaczeniu diagnostycznym.

Największą wartość predykcyjną wykazały terpeny, w szczególności seskwiterpen α -humulen, którego wzrost emisji okazał się markerem wysoce specyficznym dla stresu wywołanego przez owady gryzące/żujące. Również δ -kariofilen oraz wybrane monoterpeny (α - i β -felandren) pełniły istotną funkcję różnicującą, umożliwiając klasyfikację stresu termicznego. Jednocześnie obserwowany brak jednoznacznych wzorców emisji w odpowiedzi na żerowanie owadów ssących podkreśla ograniczenia wynikające z dostępnego zbioru danych oraz z wysokiej zmienności biologicznej reakcji roślin.

Wyniki badań wskazują, że algorytmy uczenia maszynowego analizujące wzorce emisji LZO mają potencjał diagnostyczny i mogą stanowić kluczowy

element systemów przetwarzających dane z czujników do wczesnego wykrywania stresu roślin z uwzględnieniem/rozróżnieniem jego przyczyny. Rozwój takiej technologii wymaga jednak opracowania rozbudowanych, standaryzowanych baz danych tworzonych w kontrolowanych warunkach eksperymentalnych. Niezbędne jest również wdrożenie bardziej precyzyjnych metod pomiaru stężeń związków lotnych oraz połączenie łatwo interpretowalnych modeli sztucznej inteligencji, takich jak drzewa decyzyjne, z bardziej zaawansowanymi algorytmami uczącymi się z dużych zbiorów danych. Dopiero takie podejście pozwoli określić pełną użyteczność profili emisji LZO jako wskaźników rodzaju stresu i stworzyć systemy detekcji zdolne do praktycznego zastosowania w monitoringu upraw szklarniowych.

Literatura

1. Ángeles López, Y. I., Martínez-Gallardo, N. A., Ramírez-Romero, R., López, M. G., Sánchez-Hernández, C., Délano-Frier, J. P. (2012). Cross-kingdom effects of plant-plant signaling via volatile organic compounds emitted by tomato (*Solanum lycopersicum*) plants infested by the greenhouse whitefly (*Trialeurodes vaporariorum*). *Journal of Chemical Ecology*, 38(11), 1376-1386. <https://doi.org/10.1007/s10886-012-0201-z>
2. Arafa, R. A., Kamel, S. M., Taher, D. I., Solberg, S. Ø., Rakha, M. T. (2022). Leaf extracts from resistant wild tomato can be used to control late blight (*Phytophthora infestans*) in the cultivated tomato. *Plants*, 11(14), 1824. <https://doi.org/10.3390/plants11141824>
3. Chen, L., Li, X., Zhang, J., He, T., Huang, J., Zhang, Z., Wang, Y., Hafeez, M., Zhou, S., Ren, X., Hou, Y., Lu, Y. (2021). Comprehensive metabolome and volatilome analyses in eggplant and tomato reveal their differential responses to *Tuta absoluta* infestation. *Frontiers in Plant Science*, 12, 757230. <https://doi.org/10.3389/fpls.2021.757230>
4. Copolovici, L., Kännaste, A., Pazouki, L., Niinemets, Ü. (2012). Emissions of green leaf volatiles and terpenoids from *Solanum lycopersicum* are quantitatively related to the severity of cold and heat shock treatments. *Journal of Plant Physiology*, 169(7), 664-672. <https://doi.org/10.1016/j.jplph.2011.12.019>
5. Cui, S., Inocente, E. A. A., Acosta, N., Keener, Harold. M., Zhu, H., Ling, P. P. (2019). Development of fast e-nose system for early-stage diagnosis of

- aphid-stressed tomato plants. *Sensors*, 19(16), 3480. <https://doi.org/10.3390/s19163480>
6. Deguine, J.-P., Aubertot, J.-N., Flor, R. J., Lescourret, F., Wyckhuys, K. A. G., Ratnadass, A. (2021). Integrated pest management: good intentions, hard realities. A review. *Agronomy for Sustainable Development*, 41(3), 38. <https://doi.org/10.1007/s13593-021-00689-w>
7. D'Esposito, D., Guadagno, A., Amoroso, C. G., Cascone, P., Cencetti, G., Michelozzi, M., Guerrieri, E., Ercolano, M. R. (2023). Genomic and metabolic profiling of two tomato contrasting cultivars for tolerance to *Tuta absoluta*. *Planta*, 257(3), 47. <https://doi.org/10.1007/s00425-023-04073-8>
8. Disi, J. O., Zebelo, S., Ngumbi, E., Fadamiro, H. Y. (2017). Cis-jasmone primes defense pathways in tomato via emission of volatile organic compounds and regulation of genes with consequences for *Spodoptera exigua* oviposition. *Arthropod-Plant Interactions*, 11(4), 591-602. <https://doi.org/10.1007/s11829-017-9503-y>
9. Dyrektywa Parlamentu Europejskiego i Rady 2009/128/WE z dnia 21 października 2009 r. ustanawiająca ramy wspólnotowego działania na rzecz zrównoważonego stosowania pestycydów, art. 14. (2009). Dziennik Urzędowy Unii Europejskiej L 309, 71-86.
10. Farag, M. A., Paré, P. W. (2002). C6-Green leaf volatiles trigger local and systemic VOC emissions in tomato. *Phytochemistry*, 61(5), 545-554. [https://doi.org/10.1016/S0031-9422\(02\)00240-6](https://doi.org/10.1016/S0031-9422(02)00240-6)
11. Gan, Z., Zhou, Q., Zheng, C., Wang, J. (2023). Challenges and applications of volatile organic compounds monitoring technology in plant disease diagnosis. *Biosensors and Bioelectronics*, 237, 115540. <https://doi.org/10.1016/j.bios.2023.115540>
12. Gargiulo, S., Ruocco, M., Loreto, F., Faino, L., Monti, M. M. (2025). Volatile organic compounds in *Solanum lycopersicum* leaves and their roles in plant protection. *Horticulture Research*, 12(10), uhaf181. <https://doi.org/10.1093/hr/uhaf181>
13. Ghosh, S., Didi-Cohen, S., Cna'ani, A., Kontsedalov, S., Lebedev, G., Tzin, V., Ghanim, M. (2022). Comparative analysis of volatiles emitted from tomato and pepper plants in response to infection by two whitefly-transmitted persistent viruses. *Insects*, 13(9), 840. <https://doi.org/10.3390/insects13090840>

14. Gougherty, A. V., Davies, T. J. (2021). Towards a phylogenetic ecology of plant pests and pathogens. *Philosophical Transactions of the Royal Society B*, 376(1837), 20200359. <https://doi.org/10.1098/rstb.2020.0359>
15. Hernández-Aparicio, F., Lisón, P., Rodrigo, I., Bellés, J. M., López-Gresa, M. P. (2021). Signaling in the tomato immunity against fusarium oxysporum. *Molecules*, 26(7), 1818. <https://doi.org/10.3390/molecules26071818>
16. Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90-95. <https://doi.org/10.1109/MCSE.2007.55>
17. Islam, Md. N., Hasanuzzaman, A. T. M., Zhang, Z.-F., Zhang, Y., Liu, T.-X. (2017). High level of nitrogen makes tomato plants releasing less volatiles and attracting more *Bemisia tabaci* (Hemiptera: Aleyrodidae). *Frontiers in Plant Science*, 8. <https://doi.org/10.3389/fpls.2017.00466>
18. Jansen, R. M. C., Miebach, M., Kleist, E., Van Henten, E. J., Wildt, J. (2009). Release of lipoxygenase products and monoterpenes by tomato plants as an indicator of *Botrytis cinerea* -induced stress. *Plant Biology*, 11(6), 859-868. <https://doi.org/10.1111/j.1438-8677.2008.00183.x>
19. Kasal, T. (2015). *Use of biogenic volatile organic compounds to assess the health status of tomato plants (Solanum lycopersicum) cv. "Moneymaker"*. Rozprawa doktorska, Rheinische Friedrich-Wilhelms-Universität Bonn.
20. Kasal-Slavik, T., Eschweiler, J., Kleist, E., Mumm, R., Goldbach, H. E., Schouten, A., Wildt, J. (2017). Early biotic stress detection in tomato (*Solanum lycopersicum*) by BVOC emissions. *Phytochemistry*, 144, 180-188. <https://doi.org/10.1016/j.phytochem.2017.09.006>
21. Kergunteuil, A., Coqueret, V., Larbat, R., Adamowicz, S., Bot, J. L., Robin, C. (2021). Methodological and ecological caveats in deciphering plant volatile emissions: The case study of tomato exposed to herbivory and resource limitation. *Research Square*. <https://doi.org/10.21203/rs.3.rs-419451/v1>
22. Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B., Bussonnier, M., Frederic, J., Kelley, K., Hamrick, J., Grout, J., Corlay, S., Ivanov, P., Avila, D., Abdalla, S., Willing, C., Jupyter Development Team. (2016). Jupyter Notebooks – a publishing format for reproducible computational workflows. W: F. Loizides, B. Schmidt (red.), *Positioning and Power in Academic Publishing: Players, Agents and Agendas* (s. 87-90). IOS Press. <https://doi.org/10.3233/978-1-61499-649-1-87>

23. Kutty, N. N., Mishra, M. (2023). Dynamic distress calls: volatile info chemicals induce and regulate defense responses during herbivory. *Frontiers in Plant Science*, 14, 1135000. <https://doi.org/10.3389/fpls.2023.1135000>
24. Lin, P., Paudel, S., Bin Zainuddin, N., Tan, C., Helms, A., Ali, J. G., Felton, G. W. (2022). Low water availability enhances volatile-mediated direct defences but disturbs indirect defences against herbivores. *Journal of Ecology*, 110(11), 2759-2771. <https://doi.org/10.1111/1365-2745.13987>
25. Liu, X., Bowyer, K. W., Hall, L. O. (2004). Decision trees work better than feed-forward back-prop neural nets for a specific class of problems. W: *2004 IEEE International Conference on Systems, Man and Cybernetics (IEEE Cat. No.04CH37583) vol. 6* (s. 5969-5974). IEEE. <https://doi.org/10.1109/ICSMC.2004.1401150>
26. López-Gresa, M. P., Lisón, P., Campos, L., Rodrigo, I., Rambla, J. L., Granell, A., Conejero, V., Bellés, J. M. (2017). A non-targeted metabolomics approach unravels the vocs associated with the tomato immune response against *Pseudomonas syringae*. *Frontiers in Plant Science*, 8, 1188. <https://doi.org/10.3389/fpls.2017.01188>
27. Maes, K., Debergh, P. C. (2003). Volatiles emitted from in vitro grown tomato shoots during abiotic and biotic stress. *Plant Cell, Tissue and Organ Culture*, 75(1), 73-78. <https://doi.org/10.1023/A:1024650006740>
28. Martina, M., Tikunov, Y., Portis, E., Bovy, A. G. (2021). The genetic basis of tomato aroma. *Genes*, 12(2), 226. <https://doi.org/10.3390/genes12020226>
29. Meijer, D., Van Der Vleut, J., Weldegergis, B. T., Costaz, T., Duarte, M. V. A., Pekas, A., Van Loon, J. J. A., Dicke, M. (2023). Effects of far-red light on tritrophic interactions between the two-spotted spider mite (*tetranychus urticae*) and the predatory mite *Phytoseiulus persimilis* on tomato. *Pest Management Science*, 79(5), 1820-1828. <https://doi.org/10.1002/ps.7358>
30. Mina, U., Kumar, P., Varshney, C. (2010). Effect of ozone exposure on growth, yield and isoprene emission from tomato (*lycopersicon esculentum* L.) plants. *Journal of Fruit and Ornamental Plant Research*, 72(1), 35-48. <https://doi.org/10.2478/v10032-010-0004-0>
31. Nagalingam, S., Seco, R., Musaev, K., Basu, C., Kim, S., Guenther, A. (2022). Impact of heat stress on foliar biogenic volatile organic compound emission and gene expression in tomato (*solanum lycopersicum*) seedlings. *Elementa: Science of the Anthropocene*, 10(1), 00096. <https://doi.org/10.1525/elementa.2021.00096>

32. Nawrocka, J., Szymczak, K., Maćkowiak, A., Skwarek-Fadecka, M., Małolepsza, U. (2022). Determination of reactive oxygen or nitrogen species and novel volatile organic compounds in the defense responses of tomato plants against *Botrytis cinerea* induced by *Trichoderma virens* trs 106. *Cells*, 11(19), 3051. <https://doi.org/10.3390/cells11193051>
33. Pagadala Damodaram, K. J., Gadad, H. S., Parepally, S. K., Vaddi, S., Ramanana Hunashikatti, L., Bhat, R. M. (2021). Low moisture stress influences plant volatile emissions affecting herbivore interactions in tomato, *Solanum lycopersicum*. *Ecological Entomology*, 46(3), 637-650. <https://doi.org/10.1111/een.13012>
34. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.
35. Peñuelas, J., Llusia, J. (2001). The complexity of factors driving volatile organic compound emissions by plants. *Biologia Plantarum*, 44(4), 481-487. <https://doi.org/10.1023/A:1013797129428>
36. Raghava, T., Ravikumar, P., Hegde, R., Kush, A. (2010). Spatial and temporal volatile organic compound response of select tomato cultivars to herbivory and mechanical injury. *Plant Science*, 179(5), 520-526. <https://doi.org/10.1016/j.plantsci.2010.07.020>
37. Silva, D. B., Weldegergis, B. T., Van Loon, J. J. A., Bueno, V. H. P. (2017). Qualitative and quantitative differences in herbivore-induced plant volatile blends from tomato plants infested by either *Tuta absoluta* or *Bemisia tabaci*. *Journal of Chemical Ecology*, 43(1), 53-65. <https://doi.org/10.1007/s10886-016-0807-7>
38. Spanò, R., Mastrochirico, M., Longobardi, F., Cervellieri, S., Lippolis, V., Mascia, T. (2023). Characterization of volatile organic compounds in grafted tomato plants upon potyvirus necrotic infection. *Journal of Integrative Agriculture*, 22(8), 2426-2440. <https://doi.org/10.1016/j.jia.2023.02.032>
39. Sun, Y., Cao, H., Yin, J., Kang, L., Ge, F. (2010). Elevated CO₂ changes the interactions between nematode and tomato genotypes differing in the JA pathway. *Plant, Cell & Environment*, 33(5), 729-739. <https://doi.org/10.1111/j.1365-3040.2009.02098.x>

40. The pandas development team. (2024). *pandas-dev/pandas: Pandas (v2.3.2.)* [Software]. Zenodo. <https://doi.org/10.5281/zenodo.17229934>
41. Tomescu, D., Șumălan, R., Copolovici, L., Copolovici, D. (2017). The influence of soil salinity on volatile organic compounds emission and photosynthetic parameters of *Solanum lycopersicum* L. varieties. *Open Life Sciences*, 12(1), 135-142. <https://doi.org/10.1515/biol-2017-0016>
42. Ustawa z dnia 8 marca 2013 r. o środkach ochrony roślin (Dz.U. z 2013 r. poz. 455).
43. Vehar, A., Maršić, N. K., Železnikar, Š., Potočnik, D., Strojnik, L., Petkovšek, M. M., Šircelj, H., Kastelec, D., Kovačič, A., Pintar, M., Heath, D., Heath, E., Ogrinc, N. (2025). Influence of contaminants of emerging concern on the primary and secondary metabolites of hydroponically grown tomatoes. *Food Chemistry*, 491, 145226. <https://doi.org/10.1016/j.foodchem.2025.145226>
44. Vescio, R., Caridi, R., Laudani, F., Palmeri, V., Zappalà, L., Badiani, M., Sorgonà, A. (2022). Abiotic and herbivory combined stress in tomato: Additive, synergic and antagonistic effects and within-plant phenotypic plasticity. *Life*, 12(11), 1804. <https://doi.org/10.3390/life12111804>
45. Zebelo, S., Piorkowski, J., Disi, J., Fadamiro, H. (2014). Secretions from the ventral eversible gland of Spodoptera exigua caterpillars activate defense-related genes and induce emission of volatile organic compounds in tomato, *Solanum lycopersicum*. *BMC Plant Biology*, 14(1), 140. <https://doi.org/10.1186/1471-2229-14-140>
46. Zhang, J., Zeng, L., Chen, S., Sun, H., Ma, S. (2018). Transcription profile analysis of *Lycopersicum esculentum* leaves, unravels volatile emissions and gene expression under salinity stress. *Plant Physiology and Biochemistry*, 126, 11-21. <https://doi.org/10.1016/j.plaphy.2018.02.016>

mgr Janusz Zemła¹

Helvoet Polska Sp. z o.o.

WDROŻENIE SYSTEMU WIZYJNEGO OPARTEGO NA SZTUCZNEJ INTELIGENCJI W KONTROLI JAKOŚCI PRODUKTU – STUDIUM PRZYPADKU Z HELVOET POLSKA

IMPLEMENTATION OF AN ARTIFICIAL INTELLIGENCE-BASED VISION SYSTEM IN PRODUCT QUALITY CONTROL: A CASE STUDY OF HELVOET POLAND

Streszczenie

Celem rozdziału jest przedstawienie wyników wdrożenia systemu wizyjnego opartego na sztucznej inteligencji AI (ang. *AI-based vision* – system wizyjny oparty na sztucznej inteligencji) w kontroli jakości wyrobu wulkanizowanego w Helvoet Polska. We wstępie uzasadniono ekonomiczne i operacyjne przesłanki zmiany (koszty jakości, ograniczenia kontroli manualnej) oraz porównano klasyczne systemy regulowe z podejściem zintegrowanym z PLC (ang. *programmable logic controller* – programowalny sterownik logiczny). Następnie zaprezentowano kontekst procesu oraz metodykę studium przypadku z porównaniem przed-po w dwóch porównywalnych oknach czasowych. Rdzeń rozdziału obejmuje opis architektury (kamera-optyka-oświetlenie-PLC), przebieg wdrożenia (ROI, szkolenia, uruchomienie, walidacja) oraz wyniki, w tym spadek poziomu braków. Każdy z analizowanych okresów obejmował cztery

¹ e-mail: janusz.zemla@helvoet.nl

Zemła, J. (2026). Wdrożenie systemu wizyjnego opartego na sztucznej inteligencji w kontroli jakości produktu – studium przypadku z Helvoet Polska. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 119-134). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_7

tygodnie produkcji, co pozwoliło na porównanie wyników w zbliżonych warunkach operacyjnych, jednak relatywnie krótki czas obserwacji stanowi ograniczenie badania. Dyskusja identyfikuje czynniki sukcesu (stabilne warunki optyczne, poziom kontroli) i obszary do poprawy (krawędzie 3D, próg adaptacyjny, diagnostyka zabrudzeń optyki). W zakończeniu omówiono ograniczenia (jedno gniazdo, jeden wyrób) i sformułowano implikacje dla skalowania rozwiązania.

Słowa kluczowe: AI-vision, kontrola jakości, wizja maszynowa, edge learning

Abstract

The aim of this chapter is to present the results of implementing an AI-based vision system in the quality control of a vulcanized product at Helvoet Poland. The introduction outlines the economic and operational rationale for the change (quality-related costs, limitations of manual inspection) and compares classical rule-based systems with an approach integrated with a PLC (programmable logic controller). The following section presents the process context and the case-study methodology, including a “before-after” comparison across two comparable time windows. The core of the article covers the system architecture (camera-optics-lighting-PLC), the implementation workflow (ROI, training, commissioning, validation), and the results, including a reduction in defect rates. The discussion identifies success factors (stable optical conditions, inspection coverage) and areas for improvement (3D edges, adaptive thresholding, optical contamination diagnostics). The conclusion addresses limitations (single station, single product) and formulates implications for scaling the solution.

Keywords: AI vision, quality control, machine vision, edge learning

Wstęp

Rosnąca złożoność wyrobów i skracające się cykle życia produktów windują koszty jakości CoQ (ang. *cost of quality* – łączny koszt jakości: prewencja, ocena oraz koszty niezgodności wewnętrznych i zewnętrznych), w szczególności koszty niezgodności wewnętrznej (braki, przeróbki) i zewnętrznej (reklamacje). CoQ obejmuje jednak nie tylko straty bezpośrednie, lecz także komponenty prewencji i oceny, które rosną nieliniowo wraz ze wzrostem wariantowości i złożoności portfolio. Kontrola manualna, choć elastyczna, jest podatna na zmęczenie, różnice percepcyjne i trudna do ścisłej standaryzacji przy subtelnych defektach powierzchniowych; typowy jest też dryf kryteriów akceptacji między zmianami i operatorami, co ujawniają badania MSA (ang. *measurement*

system analysis – analiza systemu pomiarowego) poprzez podwyższony udział %GRR (ang. *gage repeatability & reproducibility* – procentowy udział powtarzalności i odtwarzalności w całkowitej zmienności). W praktyce człowiek jako detektor manualny bywa wąskim gardłem stabilności jakości i źródłem zmienności decyzyjnej, a obciążenie poznawcze i monotonia pracy skutkują spadkiem czułości detekcji po kilku godzinach zmiany oraz wzrostem ryzyka błędów. Podejście to koresponduje z teorią ograniczeń, wskazującą na konieczność eliminacji wąskich gardeł w przepływie procesu (Goldratt, Cox, 2021). Dodatkowo, rosnące oczekiwania audytorów klienta oraz niezależnych audytorów zewnętrznych w zakresie śladu decyzyjnego i replikowalności oceny jakości stawiają pod znakiem zapytania skalowalność wyłącznie manualnych inspekcji w środowisku produkcji wielowariantowej. Coraz częściej to właśnie wymogi zgodności i śledzalności stają się katalizatorem inwestycji w automatyczną inspekcję, bo przejście z decyzji subiektywnych na mierzalne kryteria pozwala ograniczyć spory reklamacyjne i skracać cykl.

Klasyczne systemy wizyjne opierają się na ręcznie definiowanych cechach i progach. Są przewidywalne, lecz wrażliwe na zmiany oświetlenia, drobne odchylenia pozycjonowania, starzenie oprzyrządowania czy tolerancje materiałowe, przez co każda zmiana środowiska wymusza ręczny zwrot lub powrót i podnosi TCO (ang. *total cost of ownership* – całkowity koszt posiadania/utrzymania) oraz ryzyko błędów konfiguracyjnych. Systemy AI-vision (wizyjna kontrola jakości oparta na sztucznej inteligencji), w tym *edge learning* zastosowany w kamerze wykorzystywanej w Helvoet Polska, uczą się na przykładach OK/NOK (wyrób zgodny/niezgodny), co zwiększa odporność na naturalną zmienność procesu i umożliwia ponowne uczenie po pojawieniu się nowych wariantów defektów. W ostatnich latach rozwój przemysłowych systemów wizyjnych jest silnie powiązany z koncepcją *edge computing*, w której analiza obrazu realizowana jest bezpośrednio na urządzeniu pomiarowym lub w jego bezpośrednim otoczeniu. Takie podejście pozwala ograniczyć opóźnienia przetwarzania, zwiększyć niezawodność działania systemu oraz ułatwia integrację z systemami sterowania produkcją. Rozwiązania edge-AI są obecnie szeroko stosowane w architekturach Industry 4.0, szczególnie w obszarze automatycznej kontroli jakości i monitorowania procesów produkcyjnych (Shi i in., 2016; Lee i in., 2015).

Modele trenowane na reprezentatywnych próbkach lepiej absorbują zmienność, ale pozostają wrażliwe na dryf danych i niezbilansowanie klas; dlatego konieczne jest budowanie przekrojowych zbiorów walidacyjnych w czasie oraz stały monitoring. Zastosowane podejście do trenowania modeli edge wpisuje się w fundamenty współczesnego uczenia głębokiego, opartego na reprezentacjach hierarchicznych i odporności na zmienność danych (Goodfellow i in., 2016). W praktyce przemysłowej sprawdza się architektura hybrydowa: warstwa AI do klasyfikacji złożonych wzorców co minimalizuje ryzyko fałszywie ujemnych decyzji na obszarach bezpieczeństwa i funkcjonalności. Z perspektywy sterowania procesem kluczowa jest integracja z PLC (ang. *programmable logic controller* – programowalny sterownik linii/maszyny): sygnały OK/NOK, triggery, blokady bezpieczeństwa oraz reakcji międzystanowiskowych. Równolegle konieczne jest logowanie metadanych (czas, ID stanowiska, wynik), co zapewnia audytowalność i umożliwia analizy przyczynowe. Integrację warto uzupełnić mechanizmami *fail-safe* (bezpieczne zachowanie przy błędzie, np. domyślne odrzucenie) i kontrolowaną degradacją do logiki regulowej, gdy pewność klasyfikacji spada poniżej ustalonego progu zaufania. Logowane metadane muszą spełniać wymagania *traceability* (identyfikowalności decyzji i partii) i bezpieczeństwa informacji; ich systematyczna analiza SPC (ang. *statistical process control* – statystyczne sterowanie procesem) powinna zasilać cykle 8D (ośmiostopniowe rozwiązywanie problemów)/PDCA (ang. *plan-do-check-act* – cykl doskonalenia) oraz standaryzację pracy.

Praktyczne wdrożenia wymagają jasnych CTQ, stabilnych warunków optycznych (kamera-optyka-oświetlenie), procedur etykietowania danych, polityki wersjonowania modeli oraz zdefiniowanej roli właściciela modelu. Warunkiem skalowalności jest konsekwentna kontrola środowiska optycznego (kalibracja ekspozycji, czystość optyki, stabilizacja pozycjonowania), ponieważ każdy regres w tych obszarach bezpośrednio obniża jakość inferencji. Dodatkowo rekomenduje się okresowe „re-kwalifikacje” modelu (np. kwartalne) na zestawie złotych próbek i świeżych danych produkcyjnych, pracę w trybie *shadow-mode* (równoległa praca modelu bez wpływu na decyzje) przed wdrożeniem nowej wersji oraz formalny *change control* (kontrolę zmian) obejmujący warstwy IT (technologia informacyjna – środki i procedury przetwarzania oraz przechowywania informacji) i OT (ang. *operational technology*

– technologia operacyjna sterująca maszynami i procesami), wraz z procedurą *rollback* (powrotu do poprzedniej wersji) i kopiami zapasowymi.

Mechanizmy adaptacyjnego dostrajania progów decyzyjnych oraz iteracyjne usprawnianie działania klasyfikatora wpisują się w logikę uczenia ze wzmocnieniem, opartego na ciągłym reagowaniu na informację zwrotną z procesu (Sutton, Barto, 2018). Z perspektywy finansowej, uzasadnienie biznesowe powinno łączyć redukcję scrapu i FR (ang. *false reject* – fałszywe odrzucenia wyrobów dobrych) z kosztami reklamacji i przestojów, a także uwzględniać efekt uczenia organizacyjnego (krótszy rozruch po przebrojeniach i szybsza reakcja na odchylenia). Integracja systemu AI-vision z mechanizmami *fail-safe* i kontrolą wersji odzwierciedla współczesne podejście do bezpiecznej sztucznej inteligencji, akcentujące potrzebę nadzoru i przewidywalności działania modeli (Russell, 2019). Wreszcie, skuteczność rozwiązania jest tak samo techniczna, jak organizacyjna: niezbędne są szkolenia operatorów i UR (Utrzymania Ruchu – służb odpowiedzialnych za dostępność i niezawodność parku maszynowego), jasne role w modelu „*human-in-the-loop*” (zatwierdzanie przypadków granicznych) oraz polityka etyczna i prawna przetwarzania obrazów (retencja, dostęp, zgodność z wymaganiami klienta i regulacjami).


Kontekst Helvoet i metodyka badania własnego

Firma Helvoet wytwarza precyzyjne komponenty polimerowe i elastomerowe dla branż o wysokich wymaganiach jakościowych, w tym OEM (ang. *original equipment manufacturer* – producenci wyrobów finalnych). Analizowane gniazdo dotyczyło detalu formowanego wtryskowo z krytycznymi powierzchniami funkcyjnymi; typowe wady: zadziór, niedolew, wtrącenia, mikropęknięcia, przebarwienia. W portfolio Helvoet znajdują się m.in. uszczelnienia, elementy prowadzące, gniazda zaworowe i precyzyjne wkładki dla automotive oraz komponenty o podwyższonej czystości dla sektorów medycznego i technologicznego, co implikuje wysokie wymagania co do stabilności barwy, geometrii i chropowatości powierzchni.

Specyfika materiałowa (np. elastomery napełniane, mieszanki o zróżnicowanej reologii) sprzyja subtelным artefaktom powierzchniowym, których detekcja bywa trudna dla ludzkiego oka przy zmiennej iluminacji i różnicach połysku. Zastosowane podejście do akwizycji i przetwarzania obrazu odpowiada

klasycznym zasadom komputerowego rozpoznawania wzorców, obejmującym stabilizację oświetlenia, geometrii i jakości sygnału wejściowego (Chmielewski, Trawiński, 2004). Dodatkowym wyzwaniem jest wrażliwość niektórych gatunków tworzyw na starzenie termiczne i ślady demontażu, co podnosi ryzyko defektów późnych. Wymagania klientów w zakresie PPM (ang. *parts per million* – liczba niezgodności na milion sztuk) i *traceability* (identyfikowalność partii i decyzji) powodują, że kontrola musi identyfikować wady rzędu minimum dziesiątek mikrometrów, a więc na granicy percepcji manualnej. W takich warunkach klasy kontrolne muszą być jednoznaczne OK/NOK (zgodny/niezgodny) lub *rework* (do poprawy), a reguły decyzji odtwarzalne niezależnie od zmiany i obciążenia poznawczego operatora.

Z perspektywy SPC (ang. *statistical process control* – statystyczne sterowanie procesem) krytyczne jest szybkie sprzężenie zwrotne do parametrów procesu (temperatury, ciśnienia, czasu docisku), aby minimalizować długość serii wadliwej po wystąpieniu dryfu procesu. Do czasu wdrożenia systemu wizyjnego (ang. *AI-based vision* – system wizyjny oparty na sztucznej inteligencji) kontrola jakości była realizowana manualnie przez operatorów, wsparta wzorcami referencyjnymi i instrukcjami obrazkowymi lub filmowymi nagrywanymi i tworzonymi przez inżynierów procesu. Weryfikacja odbywała się na dedykowanym przyrządzie z wielogniazdową płytą odkładczą; operator układał detale, oceniał geometrię i czystość powierzchni przy świetle stanowiskowym, po czym zamykał pokrywę dociskową stabilizującą pozycję elementów na czas dalszych operacji. Rozwiązanie, choć elastyczne, generowało zmienność oceny między zmianami i nie tworzyło cyfrowego śladu decyzyjnego (Rysunek 1).




Rysunek 1. Przyrząd do manualnej kontroli wizualnej detali przed zamknięciem pokrywy stanowiska, kontrolnego

Źródło: opracowanie własne (Helvoet Polska).

Audyty MSA (ang. *measurement system analysis* – analiza systemu pomiarowego) wykazywały istotny udział % GRR (ang. *gage repeatability & reproducibility* – procentowy wkład powtarzalności i odtwarzalności) w całkowitej zmienności dla cech wizualnych, a wskaźniki zgodności międzyoceniającej spadały wraz z upływem czasu zmiany. W praktyce prowadziło to do fluktuacji FR (ang. *false reject* – fałszywy odrzut wyrobu dobrego) oraz incydentalnych przepuści FA (ang. *false accept* – fałszywa akceptacja wyrobu wadliwego), co generowało zarówno straty jakości, jak i koszty nadkontroli.

Z kolei na Rysunku 2 przedstawiono trend spadku wskaźnika braków produkcyjnych (scrapu) w ujęciu tygodniowym. Zaznaczony punkt między tygodniem 25 a 30 wskazuje moment wdrożenia systemu wizyjnego Cognex In-Sight 8900 Series, który stanowił kluczowy element modernizacji procesu kontroli jakości. Od momentu implementacji zauważalny jest kilkuprocentowy spadek odsetka złomowanych sztuk, będący efektem znacznie dokładniejszego wykrywania defektów przez nowy system AI-vision.



Rysunek 2. Zmiana poziomu braków produkcyjnych przed i po wdrożeniu systemu AI-vision

Źródło: opracowanie własne na podstawie danych produkcyjnych Helvoet Polska.

Zastosowano studium przypadku z porównaniem przed-po, obejmujące dwa porównywalne czterotygodniowe okresy: fazę bazową (przed wdrożeniem) oraz fazę po stabilizacji ustawień systemu AI-vision. Zbiór danych obejmował łącznie 1240 obrazów detali produkcyjnych, w tym próbki wyrobów zgodnych (OK) oraz niezgodnych (NOK). Dane pochodziły z procesu produkcyjnego realizowanego w analizowanym gnieździe kontrolnym. W analizie uwzględniono 620 detali poddanych inspekcji w okresie przed wdrożeniem oraz 620 detali po wdrożeniu systemu AI-vision.

W drugiej fazie wykorzystano kamerę Cognex In-Sight 8900 Series do automatycznej inspekcji wizualnej (Cognex Corporation, 2023), umożliwiającej detekcję niezgodności na poziomie mikroszczegółów oraz natychmiastowe reagowanie na odchylenia procesowe. W efekcie wdrożenia uzyskano nie tylko redukcję scrapu, ale również spadek wskaźnika *false reject* (FR) po kalibracji optyki i ponownym uczeniu modelu na przypadkach granicznych. Zmniejszenie liczby fałszywych odrzuceń pozwoliło na ograniczenie nadkontroli, stabilizację procesu i lepsze wykorzystanie mocy produkcyjnych, co potwierdza skuteczność integracji systemu wizyjnego z koncepcją zarządzania jakością w duchu *lean manufacturing*. Etykietowanie danych zostało przeprowadzone manualnie przez inżyniera jakości na podstawie obowiązujących kryteriów kontroli wizualnej oraz wzorców referencyjnych stosowanych w procesie produkcyjnym.

Każdy obraz został przypisany do jednej z klas: OK (wyrób zgodny) lub NOK (wyrób niezgodny). Model klasyfikacyjny został wytrenowany z wykorzystaniem funkcji Edge Learning dostępnej w systemie Cognex In-Sight 8900 (Rysunek 3). Proces trenowania obejmował iteracyjne dodawanie przykładów OK/NOK oraz walidację wyników klasyfikacji. Parametry decyzyjne modelu zostały dostrojone poprzez kalibrację progu klasyfikacji (*confidence threshold*) oraz analizę przypadków granicznych.

In-Sight® 8900 Series **Reference Manual**



Rysunek 3. Kamera przemysłowa Cognex In-Sight 8900 zastosowana w systemie automatycznej kontroli jakości

Źródło: opracowanie własne (Helvoet Polska).

Stosowane mechanizmy klasyfikacji i walidacji modelu odpowiadają fundamentom rozpoznawania wzorców i uczenia maszynowego, obejmującym kontrolę jakości danych, separację zbiorów oraz analizę miar precyzji i czułości (Bishop, 2006). Kryterium gotowości do uruchomienia ustalono jako $F1$ (średnia harmoniczna precyzji i czułości) $\geq 0,95$ dla klas krytycznych oraz AUROC (ang. *area under ROC* – pole pod krzywą ROC) $\geq 0,98$ dla modelu binarnego OK/NOK. Proces uczenia modeli *edge* odwołuje się do fundamentalnych zasad działania sieci neuronowych, w których kluczową rolę odgrywa iteracyjne

kształtowanie reprezentacji poprzez propagację błędu (Nielsen, 2015). Dane treningowe podzielono na zbiory: 70% *train*, 15% *validation* i 15% *test*, co umożliwiło niezależną ocenę jakości klasyfikacji.

Architektura rozwiązania:

1. kamera przemysłowa z modulem *Edge Learning* (uczenie/inferencja na urządzeniu brzegowym) typ: In-Sight 8900,
2. optyka dobrana do wymaganej rozdzielczości przestrzennej i głębi ostrości,
3. kopułowe oświetlenie nad płytą maszynową eliminujące refleksy,
4. interfejs z PLC (*programmable logic controller* – sterownik linii/maszyny): cyfrowe I/O (wejścia/wyjścia) + kanał protokołu dla metadanych,
5. repozytorium obrazów i raportów klasyfikacji.

Integracja z PLC obejmowała sygnały OK/NOK, zatrzymania zabezpieczające (interlocki) oraz przekaz progu zaufania (*confidence threshold*) w celu warunkowego przekierowania sztuk do weryfikacji ręcznej (tryb kontroli zdegradowanej). Implementacja logiki sterującej oraz wymiana sygnałów OK/NOK między kamerą a sterownikiem odzwierciedlają fundamentalne zasady projektowania układów opartych na PLC (Broel-Plater, 2015). Pipeline danych rejestrował obrazy źródłowe, co spełnia wymagania *traceability*, tzn. zachowania obrazu, czyli fototeki zdjęć. Stabilność środowiska optycznego zapewniono dzięki kontrolowanej geometrii chwytu detali w formie pośredniej i ekranowaniu od światła zewnętrznego i okresowej kalibracji ekspozycji. Zbiór danych został oznaczony manualnie przez inżyniera jakości i operatorów procesu w klasach OK/NOK, na podstawie wzorców referencyjnych stosowanych w kontroli jakości. Na potrzeby UR (utrzymanie ruchu – służby odpowiedzialne za dostępność i niezawodność parku maszynowego) zdefiniowano rolę właściciela modelu oraz procedury ponownego uczenia po zmianach narzędziowych (np. po piaskowaniu formy). W warstwie zarządczej zastosowano kontrolę zmian i mechanizmy powrotu do wcześniejszej wersji, czyli tzw. Backupu programowego, jeśli obecna wersja uległaby uszkodzeniu.

Wynik badania własnego, czyli wdrożenie systemu wizyjnego opartego na AI na przykładzie Helvoet Polska

Badanie wskazuje, że implementacja systemu AI-vision w gnieździe kontroli końcowej przyniosła poprawę kluczowych metryk jakościowych, nie wpływając negatywnie na takt linii produkcyjnej. Istotność statystyczną różnicy poziomu braków przed i po wdrożeniu oceniono przy użyciu testu t-Studenta, przy poziomie istotności $p < 0,05$. W analizowanym okresie odnotowano spadek średniego poziomu braków (scrap), a na wykresie od momentu wdrożenia systemu widoczna jest 3% procentowa redukcja odsetka złomowanych sztuk, wynikająca z wyraźnie lepszego wykrywania defektów.

Z perspektywy analitycznej wskazuje to, że system AI-vision nie tylko pełni funkcję efektywnego narzędzia inspekcyjnego, ale również przyczynia się do obniżenia wariacji procesu, stabilizując go na wyższym poziomie dojrzałości operacyjnej. W konsekwencji organizacja przechodzi w bardziej ustrukturyzowany, oparty na danych model działania, w którym decyzje jakościowe są podejmowane z mniejszą podatnością na zmienność ludzkiej percepcji.

Wdrożenie systemu AI-vision wpisuje się w logikę ciągłego usprawniania na poziomie gemba, gdzie kluczowe jest eliminowanie źródeł strat bez nadmiernych kosztów i przy maksymalnym wykorzystywaniu wiedzy operacyjnej zespołów (Imai, 2018). Ponadto uzyskana redukcja poziomu scrapu sugeruje wystąpienie efektu synergii między automatyczną inspekcją a dotychczas stosowanymi procedurami jakościowymi. W ujęciu strategicznym wdrożenie to wpisuje się w koncepcję inteligentnych operacji, w ramach której linia produkcyjna ewoluuje z funkcji reaktywnej do roli proaktywnej, predykcyjnej i wspieranej rozwiązaniami cyfrowymi (Tabela 1).

Tabela 1. Metryki klasyfikacji systemu AI-vision

Metryka	Wartość
Precision	0.96
Recall	0.94
F1-score	0.95

Źródło: opracowanie własne (Helvoet Polska).

Wyniki wskazują na wysoką skuteczność klasyfikacji systemu AI-vision w identyfikacji defektów produkcyjnych. Z perspektywy biznesowej polepszyła

się również efektywność. Dodatkową wartością okazała się audytowalność: repozytorium obrazów i metadanych usprawniło analizy PDCA i przyspieszyło domykanie działań korygujących. Wymagania dotyczące jakości danych uczących oraz standaryzacji procesu etykietowania są spójne z praktykami inżynierii uczenia maszynowego, w których kluczową rolę odgrywa kontrola zmienności i budowa stabilnego środowiska danych (Géron, 2019). Jednocześnie potwierdzono ograniczenia: pojedyncze gniazdo i jeden typ wyrobu w fazie badania, konieczność utrzymania dyscypliny danych (etykietowanie, re-kwalifikacje modeli) oraz wrażliwość na degradację środowiska optycznego. Całościowo, wyniki wskazują, że przy spełnieniu wymogów CTQ i *governance* modelu, AI-vision stanowi realną dźwignię poprawy jakości i stabilności procesu w warunkach produkcji wielowariantowej.

Wdrożenie zrealizowano we współpracy z dostawcą, firmą Cognex. Partner najpierw przeprowadził audyt aplikacyjny gniazda (produkt/proces), następnie przygotował demonstrację koncepcji POC (ang. *proof-of-concept* – demonstracja wykonalności i wartości rozwiązania) i uruchomił miesięczny pilotaż na wybranym stanowisku Helvoet oraz na bezpośredniej maszynie wtryskowej. Zakres prac obejmował dobór i kalibrację kamery/optyki/oświetlenia, integrację z PLC (ang. *programmable logic controller* – sterownik maszyny/linii) poprzez cyfrowe I/O (ang. *inputs/outputs* – wejścia/wyjścia sygnałowe) oraz kanał do przekazywania metadanych, przygotowanie zbiorów referencyjnych OK/NOK (zgodny/niezgodny), wstępne trenowanie modeli edge (ang. *edge learning* – uczenie/inferencja na urządzeniu brzegowym) oraz parametryzację progów decyzyjnych i sygnałów bezpieczeństwa. Koordynacja wdrożenia, obejmująca integrację systemu, testy, walidację oraz kontrolę wersji, odpowiada dobrym praktykom zarządzania projektami IT (Wodecki, 2014).

Równolegle firma Cognex przeprowadziła szkolenia dla operatorów, inżynierów procesu oraz automatyków utrzymania ruchu, a także przekazała dane dotyczące akwizycji obrazu, etykietowania danych (OK/NOK), uruchamiania i dogrywania modeli interpretacji metryk oraz podstawowego utrzymania czyli czyszczenie optyki, kontrola ekspozycji na dane wejścia i wyjścia PLC. Wdrożenie systemu AI-vision posiada także charakter minimalnego aczkolwiek planowanego wdrożenia projektu informatycznego przy wykorzystania AI czyli wymagającego planowania, kontroli zmian oraz koordynacji zasobów zgodnie z zasadami zarządzania projektami IT (Głodziński i in., 2025).

Operacyjnie zestrojono ekspozycję i balans oświetlenia, ustandaryzowano pozycjonowanie detalu oraz dodano check-listy optyczne do instrukcji pracy. Od strony mechanicznej, czyli utrzymania ruchu, tzw. przepływ decyzyjny funkcjonuje jako deterministyczny łańcuch: trigger z PLC (wyzwolenie) → akwizycja obrazu → inferencja edge (wnioskowanie na kamerze) → decyzja OK/NOK → akcja PLC (wypchnięcie NOK, alarm, ewentualny bezpieczny stop). Testy na partiach z kontrolowanymi defektami potwierdziły wymaganą czułość przy jednoczesnej redukcji FR (ang. *false reject* – fałszywy odrzut wyrobu dobrego). Integracja systemu wizyjnego z układem sterowania oraz synchronizacja akwizycji obrazu z ruchem maszyny odzwierciedlają podstawowe zasady automatyki i robotyki przemysłowej (Zdanowicz, 2017).

W ujęciu biznesowym odnotowano spadek scrapu, mniej reklamacji oraz krótszy rozruch serii oraz, co istotne, pozytywne wyniki 4-tygodniowego pilotażu przełożyły się na decyzję zakupową na kontrolowanym produkcie odnotowano dodatkowo ~3 % redukcji scrapu względem inspekcji wyłącznie wzrokowej.

Docelowo za utrzymanie rozwiązania odpowiada wspólny zespół jakości i UR (konserwacja optyki, kalibracje), przy wsparciu dostawcy w formule II linii wsparcia (aktualizacje, konsultacje jakości danych). Po stronie Helvoet powołano rolę opiekuna dla danych/modelu w osobie inżyniera procesu oraz inżyniera automatyki w Helvoet odpowiedzialnych za przygotowanie zbiorów, walidację oraz kontrola zmian sztuk OK i NOK i możliwość powrotu do poprzedniej wersji przed publikacją kamery na maszynie.

Dyskusja i ograniczenia

Uzyskane wyniki wskazują na pozytywny wpływ wdrożenia systemu AI-vision na stabilność procesu kontroli jakości oraz na redukcję poziomu braków produkcyjnych. Automatyzacja inspekcji wizualnej umożliwiła bardziej powtarzalną ocenę jakości detali oraz ograniczenie zmienności wynikającej z czynnika ludzkiego. Zastosowanie systemu wizyjnego opartego na sztucznej inteligencji pozwoliło również na szybszą identyfikację defektów produkcyjnych oraz usprawnienie procesu podejmowania decyzji jakościowych w środowisku produkcyjnym.

Należy jednak uwzględnić ograniczenia przeprowadzonego badania. Analiza została wykonana dla jednego gniazda produkcyjnego oraz jednego typu wyrobu, co ogranicza możliwość bezpośredniej generalizacji uzyskanych wyników na inne procesy produkcyjne lub inne typy produktów. Różnice w charakterystyce materiałów, geometrii detali czy warunkach oświetleniowych mogą wpływać na skuteczność działania systemów wizyjnych i wymagają indywidualnego dostosowania konfiguracji oraz procesu uczenia modelu.

Dodatkowym ograniczeniem jest stosunkowo krótki okres obserwacji po wdrożeniu systemu. Analiza obejmowała ograniczony horyzont czasowy produkcji, co utrudnia pełną ocenę długoterminowej stabilności działania systemu oraz jego wpływu na zmienność procesu w dłuższej perspektywie. W przyszłych badaniach zasadne byłoby przeprowadzenie długookresowej analizy danych produkcyjnych, obejmującej większą liczbę partii produkcyjnych oraz różne warianty detali.

Kierunkiem dalszych prac może być również rozszerzenie wdrożenia systemu AI-vision na inne stanowiska produkcyjne oraz inne referencje produktowe, co pozwoliłoby na ocenę skalowalności rozwiązania w warunkach produkcji wielowariantowej. Dodatkowo warto rozważyć integrację danych z systemów wizyjnych z narzędziami analizy procesowej, takimi jak SPC (*statistical process control*), co mogłoby umożliwić jeszcze wcześniejsze wykrywanie odchyleń procesowych i dalsze doskonalenie systemu zarządzania jakością.

Wnioski

Po miesięcznym teście pilotażowym podjęto decyzję o zakupie systemu; wyniki pozytywnie zaskoczyły dla kontrolowanego wyrobu odnotowano spadek scrapu (odsetek braków) o 3%. względem kontroli wzrokowej. Czas cyklu gniazda nie uległ pogorszeniu latencja inferencji *edge* (czas wnioskowania na urządzeniu brzegowym) pozostawała poniżej taktu. Zmienność międzypartyjna zmalała, co przełożyło się na stabilność planu i mniejszą liczbę problemów jakościowych. Realizowane działania wpisują się w nowoczesne podejście do zarządzania jakością, akcentujące rolę danych, stabilności procesów oraz systemowego monitorowania odchyleń (Borys, 2009). Dodatkowo odnotowano spójniejszy rozruch po starcie maszyny.

Wpływ na kulturę operacyjną był istotny. Kryteria akceptacji wsparte danymi z repozytorium zwiększyły zaufanie do systemu i przyspieszyły podejmowanie decyzji o reakcji procesowej (np. korekta parametrów wtrysku gumy). Transformacja procesu kontroli jakości jest spójna z zasadami organizacji uczącej się, w której stabilność, transparentność i odpowiedzialność zespołów stanowią fundament ciągłego doskonalenia (Blikle, 2014).

AI-vision (ang. *artificial intelligence vision* – system wizyjny oparty na sztucznej inteligencji), przy spełnieniu warunków optycznych i dyscyplinie danych stanowi dźwignię poprawy jakości i stabilności procesu. Integracja z PLC (ang. *programmable logic controller* – programowalny sterownik logiczny) domyka pętlę sterowania w czasie rzeczywistym, a repozytorium obrazów/metryk umożliwia audyt i organizacyjne uczenie się. Rekomenduje się kontrolowane skalowanie rozwiązania na pokrewne produkty wytwarzane na tej samej maszynie: dla każdej nowej referencji/produktu przeprowadzić kwalifikację optyki/oświetlenia, przygotować zestaw „golden sample”, wykonać MSA (ang. *measurement system analysis* – analiza systemu pomiarowego) klasyfikatora, ustalić progi dopuszczenia (*confidence*) oraz włączyć referencję do planu kalibracji i re-treningu. Kierunek jest korzystny strategicznie dla Helvoet: ogranicza złom (*scrap*), stabilizuje jakość przy rosnącej wariantowości i wzmacnia pozycję kosztową oraz reputacyjną w łańcuchu dostaw. Ograniczeniem badania jest analiza jednego gniazda produkcyjnego oraz jednego typu wyrobu, co może ograniczać bezpośrednią generalizację wyników na inne procesy produkcyjne. Dodatkowym ograniczeniem badania jest stosunkowo krótki okres obserwacji procesu po wdrożeniu systemu, dlatego dalsze analizy powinny obejmować dłuższy horyzont czasowy produkcji.

Literatura

1. Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer. <https://doi.org/10.1007/978-0-387-45528-0>
2. Blikle, A. J. (2014). *Doktryna jakości. Rzecz o turkusowej samoorganizacji*. Onepress.
3. Borys, T. (2009). *Zarządzanie jakością. Teoria i praktyka*. PWE.
4. Broel-Plater, B. (2015). *Układy wykorzystujące sterowniki PLC*. Wydawnictwo Naukowe PWN.

5. Chmielewski, L., Trawiński, D. (2004). *Komputerowe przetwarzanie i rozpoznawanie obrazów*. Akademicka Oficyna Wydawnicza EXIT.
6. Cognex Corporation. (2023). *In-Sight 8900 Series Vision System – Technical Documentation*.
7. Géron, A. (2019). *Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow* (wyd. 2). Helion.
8. Głodziński, E., Swacha, J., Woźniak, M. (2025). *Zarządzanie projektami informatycznymi*. Wydawnictwo Naukowe PWN.
9. Goldratt, E. M., Cox, J. (2021). *Cel I: Doskonałość w produkcji*. Mint Books.
10. Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep learning*. MIT Press. <https://doi.org/10.7551/mitpress/10243.001.0001>
11. Imai, M. (2018). *Gemba Kaizen: Zdroworozsądkowe, niskokosztowe podejście do zarządzania*. MT Biznes.
12. Lee, J., Bagheri, B., Kao, H.-A. (2015). A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems. *Manufacturing Letters*, 3, 18-23. <https://doi.org/10.1016/j.mfglet.2014.12.001>
13. Nielsen, M. (2015). *Neural networks and deep learning*. Determination Press.
14. Russell, S. (2019). *Human compatible: Artificial intelligence and the problem of control*. Viking.
15. Shi, W., Cao, J., Zhang, Q., Li, Y., Xu, L. (2016). Edge computing: vision and challenges. *IEEE Internet of Things Journal*, 3(5), 637-646. <https://doi.org/10.1109/JIOT.2016.2579198>
16. Sutton, R. S., Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press.
17. Wodecki, A. (2014). *Zarządzanie projektami informatycznymi: metodyki, narzędzia, przykłady*. Wydawnictwo Naukowe PWN.
18. Zdanowicz, R. (2017). *Podstawy robotyki*. Wydawnictwo Politechniki Śląskiej.

mgr Wiktor Kolat¹, mgr inż. Wiktoria Galecka²

Uniwersytet Ekonomiczny w Katowicach

Wiktor Kowalski³

Uniwersytet Ekonomiczny we Wrocławiu

PORÓWNANIE REGRESJI LINIOWEJ (DYNAMICZNEJ AR(2)-X) I SIECI NEURONOWYCH W PROGNOZOWANIU CEN NIERUCHOMOŚCI MIESZKANIOWYCH W POLSCE – ANALIZA NA DANYCH KWARTALNYCH 2014-2024

COMPARISON OF LINEAR REGRESSION (DYNAMIC AR(2)-X) AND NEURAL NETWORKS IN FORECASTING RESIDENTIAL REAL ESTATE PRICES IN POLAND – ANALYSIS ON QUARTERLY DATA 2014-2024

Streszczenie

Celem rozdziału jest porównanie skuteczności prognozowania cen nieruchomości mieszkaniowych w Polsce za pomocą modelu regresji dynamicznej typu AR(2)-X (OLS/MNK) oraz sztucznych sieci neuronowych (ANN). Analiza oparta jest na danych

¹ <https://orcid.org/0009-0004-8718-5905>, e-mail: wiktor.kolat@ue.katowice.pl

² <https://orcid.org/0000-0001-9975-4897>

³ <https://orcid.org/0009-0009-1449-0366>

Kolat, W., Galecka, W., Kowalski, W. (2026). Porównanie regresji liniowej (dynamicznej AR(2)-X) i sieci neuronowych w prognozowaniu cen nieruchomości mieszkaniowych w Polsce – analiza na danych kwartalnych 2014-2024. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 135-160). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_8

GUS z lat 2014-2024 dotyczących rynku wtórnego w 16 miastach wojewódzkich. Przedstawiono konstrukcję modeli, ich walidację oraz ocenę jakości prognoz. Model regresji dynamicznej AR(2)-X charakteryzował się wysoką dokładnością, osiągając MAPE 2,05% i MAE 206,71 zł/m². Model sieci neuronowej MLP, choć przewyższał modele naiwne, uzyskał wyższe błędy predykcyjne: MAPE 2,24% i MAE 220,76 zł/m².

Słowa kluczowe: rynek nieruchomości, regresja liniowa, sztuczne sieci neuronowe, prognozowanie cen, analiza porównawcza

Abstract

The aim of this chapter is to compare the effectiveness of forecasting residential property prices in Poland using a dynamic regression model of the AR(2)-X type (estimated by OLS) and artificial neural networks (ANN). The analysis is based on Statistics Poland (GUS) data for 2014-2024 covering the secondary market in 16 regional capital cities. The paper presents the construction of the models, their validation, and an assessment of forecast accuracy. The AR(2)-X dynamic regression model exhibited high accuracy, achieving a MAPE of 2.05% and an MAE of PLN 206.71 per m². The MLP neural network model, although outperforming naïve benchmarks, produced higher prediction errors: a MAPE of 2.24% and an MAE of PLN 220.76 per m².

Keywords: real estate market, linear regression, artificial neural networks, price forecasting, comparative analysis

Wstęp

Rynek nieruchomości to złożony segment gospodarki, którego struktura i mechanizmy działania ulegają ciągłym przemianom (Żróbek i in., 2024).

Współczesny rynek nieruchomości mieszkaniowych charakteryzuje się cechami, które odróżniają go od innych segmentów gospodarki, są to m.in. (Bryx, 2006; Gołąbeska, 2011; Grzywińska-Rapca i in., 2024): niska elastyczność podaży, zmienna sytuacja popytowa, trwałość i unikatowość nieruchomości, długi cykl inwestycyjny, wysoka kapitałochłonność, podatność na regulacje prawne, znaczenie emocji i preferencji kupujących, cykliczność rynku, lokalność rynku oraz rola inwestorów na rynku (Bryx, 2006; Gołąbeska, 2011). W Polsce występują dwa główne segmenty rynku nieruchomości

mieszkaniowych (Kucharska-Stasiak, 2005; Gołąbeska, 2011; Grzywińska-Rapca i in., 2024):

- pierwotny – obejmuje nowe nieruchomości budowane przez deweloperów, które nie były wcześniej zamieszkane;
- wtórny – obejmuje nieruchomości już użytkowane, które są sprzedawane przez ich dotychczasowych właścicieli.

Poza czynnikami fizycznymi, które wpływają na wartość nieruchomości, a co za tym idzie na cenę (np.: zużycie budynku, lokalizacja, kształt działki, infrastruktura techniczna etc.), na jej wartość mają wpływ również czynniki makroekonomiczne (np. poziom bezrobocia, wysokość stóp procentowych, stan rozwoju gospodarczego, etap cyklu koniunkturalnego, etc.) (Mach, 2014; Zydroń i Walkowiak, 2013).

W kontekście złożoności rynku nieruchomości mieszkaniowych oraz wielości czynników wpływających na kształtowanie się cen, powstaje potrzeba opracowania skutecznych metod prognozowania.

Celem niniejszego badania jest porównanie skuteczności prognozowania średnich zagregowanych cen mieszkań w Polsce dla 16 miast wojewódzkich z wykorzystaniem dwóch podejść: modelu regresji dynamicznej AR(2)-X estymowanego MNK dla danych czasowych oraz metod z obszaru uczenia maszynowego, w szczególności sieci neuronowych. Analizę oparto na danych GUS dotyczących średnich kwartalnych cen transakcyjnych za 1 m² na rynku wtórnym dla 16 miast wojewódzkich w Polsce w latach 2014-2024.

Badanie ma na celu nie tylko porównanie dokładności prognoz obu podejść, ale także identyfikację ich względnych zalet i ograniczeń w kontekście praktycznego zastosowania na polskim rynku nieruchomości.

Podmiotami, dla których badania mogą okazać się przydatne są fundusze inwestycyjne, firmy deweloperskie czy banki, które mogą wykorzystywać dane makroekonomiczne do prognozy przyszłych cen nieruchomości w celu ustalenia strategii inwestycyjnej i rozwojowej nie dla konkretnego rynku, ale na zagregowanym poziomie całego kraju. Wyniki badań mogą zostać zastosowane również przez osoby fizyczne, które nie mają dostępu do specjalistycznych danych, których pozyskanie często wiąże się z poniesieniem dużych kosztów.

Regresja liniowa a sztuczne sieci neuronowe (ANN)

W rozdziale przez podejście regresyjne rozumie się modele liniowe estymowane metodą najmniejszych kwadratów, w tym specyfikacje dynamiczne dla danych czasowych uwzględniające opóźnienia zmiennej zależnej (ARX), co pozwala uchwycić inercję cen.

Regresja liniowa jest jedną z najstarszych technik statystycznych powszechnie stosowaną w metrologii (Puchalski, Warszawa, 2022; Warszawa, Puchalski, 2020), inżynierii (Vakhshouri, Nejadi, 2015), ekonomii, finansach (Welc, 2009), medycynie (Gorriz i in., 2026; Zapf i in., 2024; Chicco i in., 2020) oraz informatyce (Gorriz i in., 2026; Silhavy i in., 2017; Flores Hinostroza i in., 2025). Stanowi również podstawę dla wielu zaawansowanych algorytmów uczenia maszynowego. Metoda stosowana jest do szacowania liniowych zależności między zmienną zależną (objaśnianą), a jedną lub więcej zmiennymi niezależnymi (objaśniającymi) (Gorriz i in., 2026; Puchalski, Warszawa, 2022; Ampuła, 2014).

Model regresji liniowej często jest formalnie definiowany jako oczekiwana wartość zmiennej zależnej Y pod warunkiem danej wartości zmiennej niezależnej X , z dodanym składnikiem losowym (ϵ), który odpowiada za niezdeklarowane zakłócenia, błędy pomiarowe oraz czynniki nieujęte w modelu (Gorriz i in., 2026; Ampuła, 2014; Puchalski, Warszawa, 2022; Warszawa, Puchalski, 2020). W badaniach prognostycznych dla szeregów czasowych często stosuje się rozszerzenia regresji liniowej o składniki dynamiczne, w szczególności opóźnienia zmiennej zależnej (modele ARX/ARDL), co pozwala uchwycić inercję procesu i poprawić własności prognostyczne (Enders, 2015).

Standardowa metoda dopasowywania linii regresji, znana jako metoda najmniejszych kwadratów (ang. *Ordinary Least Squares* – OLS), polega na minimalizacji sumy kwadratów reszt, czyli różnic między wartościami obserwowanymi a przewidywanymi przez model (Ampuła, 2014; Puchalski, Warszawa, 2022; Silhavy i in., 2017; Warszawa, Puchalski, 2020). OLS jest powszechnie stosowana (Ampuła, 2014; Gorriz i in., 2026) i stanowi fundament dla wielu zaawansowanych technik uczenia maszynowego, takich jak regresja grzbietowa (ang. *ridge*) czy tzw. regresja Lasso (Gorriz i in., 2026). W kontekście danych czasowych dodatkowego znaczenia nabierają założenia dotyczące braku autokorelacji składnika losowego oraz ryzyka regresji pozornej przy

niestacjonarnych szeregach, dlatego w analizie uwzględnia się weryfikację stacjonarności oraz diagnostykę reszt (Enders, 2015; Stock, Watson, 2020).

W kontekście danych czasowych kluczowe znaczenie mają założenia dotyczące braku autokorelacji składnika losowego oraz ryzyka regresji pozornej przy niestacjonarnych szeregach, dlatego w analizie ekonometrycznej szeregów czasowych standardowo stosuje się testy stacjonarności ADF i KPSS zarówno dla zmiennej objaśnianej, jak i potencjalnych regresorów (Ghouse i in., 2018; Sarkodie, Owusu, 2020). Komplementarne zastosowanie obu testów pozwala na jednoznaczną klasyfikację procesów $I(0)$ vs $I(1)$ oraz identyfikację konieczności różnicowania zmiennych, eliminując niejednoznaczności pojedynczych testów jednostkowych (Sarkodie, Owusu, 2020). Taka procedura prewencyjnie ogranicza ryzyko regresji pozornej w modelach dynamicznych typu ARDL/ARX, stanowiąc fundament teoretyczny przed estymacją równań progностycznych (Ghouse i in., 2018).

Zalety regresji liniowej to jej prostota implementacji i interpretacji (Ampuła, 2014). Jest to szczególnie wartościowe narzędzie do tworzenia modeli progностycznych, nawet przy niskich rozmiarach prób (Fernandes i in., 2023). Metoda ta jest wykorzystywana do przewidywania przyszłych zdarzeń lub do sterowania zmienną zależną poprzez manipulowanie zmiennymi niezależnymi (Ampuła, 2014). Można zatem uznać, że regresja umożliwia analizę zależności statystycznych i identyfikację współzmienności kluczowych czynników, natomiast wnioskowanie przyczynowe wymaga spełnienia dodatkowych założeń identyfikacyjnych.

Mimo swojej użyteczności, regresja liniowa obarczona jest istotnymi ograniczeniami i powinna być stosowana z pełną świadomością założeń oraz warunków poprawności (Ampuła, 2014; Hazimeh, Mazumder, 2020; Zapf i in., 2024). Wymaga spełnienia kilku kluczowych założeń, takich jak liniowość, niezależność, homoskedastyczność i brak doskonałej współliniowości (Ampuła, 2014; Aguinis i in., 2005; Poole, O'Farrell, 1971; Zapf i in., 2024). Niespełnienie tych założeń, zwłaszcza homoskedastyczności, może sprawić, że analizy oparte na teście F stają się nieprecyzyjne (obciążone) i statystycznie nieważne. Jest to widoczne w przypadkach z heteroskedastycznością, gdzie założenia testu F nie zostają spełnione (Baum, Lewbel, 2019; Gorris i in., 2026). W kontekście uczenia maszynowego, chociaż testy istotności statystycznej i przedziały predykcji mogą być przeprowadzane na resztach modeli uczenia

maszynowego, to jest rzadko spotykane w literaturze ML (ang. *machine learning* – uczenie maszynowe), skupia się ona na empirycznych miarach wydajności (Gorritz i in., 2026). Ponadto, dla danych niezgodnych z rozkładem Gaussa, tradycyjne metody mogą być niewystarczające (Gorritz i in., 2026). W modelach z wieloma współzmiennymi i heteroskedastycznością, pojawiają się złożoności w wnioskowaniu (Cattaneo i in., 2018). Autorzy (Warsza, Puchalski, 2020) zauważyli, że w pewnych specyficznych sytuacjach, gdy mamy do czynienia ze skorelowanymi danymi pomiarowymi, i jeśli ich macierz kowariancji nie jest dodatnio ani ujemnie określona w sensie matematycznym, mianownik może stać się równy zeru ($\Delta = 0$). Autorzy zwracają również uwagę, że w literaturze dotyczącej regresji liniowej brakuje informacji na temat tej osobliwości oraz wskazówek, jak jej uniknąć lub jak postępować, gdy ona wystąpi (Warsza, Puchalski, 2020).

Sztuczne sieci neuronowe (ang. *Artificial Neural Networks* – ANN) to nieliniowe narzędzia do modelowania danych statystycznych, zdolne do opisywania złożonych interakcji między danymi wejściowymi i wyjściowymi oraz odkrywania wzorców (Mondal i in., 2025; Qamar, Zardari, 2023). Zalicza się je do najważniejszych i najbardziej rozpowszechnionych klas algorytmów uczenia maszynowego (Haykin, 2009; Schmidhuber, 2015). Ich koncepcja została zainspirowana biologicznymi strukturami mózgu, w szczególności mechanizmem przetwarzania informacji przez neurony (Haykin, 2009; Schmidhuber, 2015). Podstawowym elementem ANN jest sztuczny neuron, który przyjmuje sygnały wejściowe, przekształca je za pomocą wag i funkcji aktywacji, a następnie przekazuje wynik dalej do kolejnych warstw (Heaton, 2017).

Formalnie, aktywacja pojedynczego neuronu opisana jest równaniem (Heaton, 2017):

$$Y = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

gdzie:

- x_i – sygnały wejściowe,
- w_i – wagi,
- b – bias (składnik przesunięcia),
- $f(\cdot)$ – nieliniowa funkcja aktywacji (np. sigmoid, ReLU, tanh),
- Y – sygnał wyjściowy neuronu

Sieci neuronowe występują w różnych architekturach – od klasycznych, wielowarstwowych perceptronów (MLP), poprzez specjalistyczne sieci konwolucyjne (CNN) i rekurencyjne (RNN), aż po nowoczesne modele oparte na architekturze transformerów (LeCun, Bengio, Hinton, 2015).

Do głównych zalet sztucznych sieci neuronowych należą (Hornik, 1991; LeCun i in., 2015; Mondal i in., 2025; Pires i in., 2023; Schmidhuber, 2015):

- uniwersalność i wszechstronność: wykazują zdolność do adaptacyjnego uczenia się na podstawie dostarczonych danych treningowych lub wcześniejszych doświadczeń;
- skalowalność i zdolność do przetwarzania dużych zbiorów danych: mogą uczyć się i podejmować decyzje w oparciu o masowe i złożone dane wejściowe, takie jak obrazy, głos i tekst. Architektury głębokich sieci neuronowych zapewniają kompozycyjne modele, w których obiekt jest przedstawiany jako warstwowa kompozycja prymitywów, gdzie cechy z niższych warstw mogą być łączone z tymi z innych warstw;
- automatyczne wykrywanie cech: w przeciwieństwie do regresji liniowej, sztuczne sieci ANN są zdolne do automatycznego odkrywania znaczących cech bezpośrednio z surowych danych, co eliminuje potrzebę ręcznej inżynierii cech.

Pomimo ogromnego potencjału, sztuczne sieci neuronowe nie są wolne od ograniczeń. Przede wszystkim ANN wymagają dużych zbiorów danych (Pires i in., 2023). Sieci neuronowe są często określane mianem „czarnych skrzynek”, ponieważ ich działanie może być trudne do odczytania i zrozumienia (Pires i in., 2023; Lipton, 2018). Kolejne ograniczenie stanowi ryzyko tzw. przeuczenia się (*overfitting*) – mają one dużą zdolność do dopasowania się do szumu w danych, co może wpływać na obniżanie ich skuteczności predykcyjnej (Goodfellow i in., 2016; Mondal i in., 2025; Pires i in., 2023). Jednocześnie wymagają dużych zasobów obliczeniowych, starannego przygotowania danych oraz świadomości ograniczeń związanych z interpretacją wyników.

Metodologia

W badaniu zastosowano regresję dynamiczną typu AR(2)-X (ARX) estymowaną metodą najmniejszych kwadratów (OLS), traktowaną jako benchmark prognostyczny w porównaniu z podejściami z obszaru uczenia maszynowego.

Zmienną objaśnianą (Y) stanowiły średnie arytmetyczne kwartalne ceny (transakcyjne) za 1 m² (zagregowana dla 16 miast wojewódzkich bez Torunia i Gorzowa Wielkopolskiego) w latach 2014Q1-2024Q4. Zmiennymi objaśniającymi (X), które pierwotnie zostały wybrane do modelu, w ujęciu kwartalnym, były: przychody przedsiębiorstw budowlanych (mln zł) (1), inwestycje na budynki i budowle (mln zł) (2), mieszkania na realizację których wydano pozwolenia lub dokonano zgłoszenia z projektem budowlanym (tys.) (3), mieszkania, których budowę rozpoczęto (tys.) (4), mieszkania oddane do użytkowania (tys.) (5), stopa oprocentowania referencyjna (stan na koniec kwartału) (%) (6), PKB wygenerowane przez budownictwo (mld zł) (7), przeciętna liczba osób w budownictwie (tys.) (8), stopa bezrobocia (%) (9), przeciętne miesięczne wynagrodzenie nominalne brutto (zł) (10) oraz inflacja (%) (11). Po zbadaniu poziomu zmienności rozumianego jako iloraz odchylenia standardowego i średniej zmienna 8 została odrzucona, ponieważ nie spełniała kryterium poziomu zmienności powyżej 10%.

Ze względu na możliwość występowania niestacjonarności szeregów czasowych przeprowadzono testy ADF oraz KPSS dla zmiennej objaśnianej i zmiennych objaśniających (w poziomach oraz dla pierwszych różnic). Wyniki wskazywały, że dla większości analizowanych zmiennych nie można przyjąć stacjonarności w poziomach, co uzasadniało dodatkową kontrolę ryzyka regresji pozornej. Zastosowano regresję dynamiczną z dwoma opóźnieniami zmiennej objaśnianej ($cena_{-1}$; $cena_{-2}$) oraz współczesnymi zmiennymi objaśniającymi. Liczbę opóźnień ograniczono do dwóch ze względu na kwartalną częstotliwość danych oraz relatywnie krótką próbę, aby zachować stabilność estymacji i uniknąć nadmiernej utraty obserwacji. Dobór regresorów przeprowadzono w sposób obiektywny poprzez pełne przeszukanie przestrzeni modeli w rozważanej klasie: przetestowano wszystkie kombinacje podzbiorów X1-X7 oraz X9-X11, przy czym w każdej specyfikacji uwzględniano $cena_{-1}$; $cena_{-2}$. Kryterium wyboru stanowiło kryterium informacyjne BIC minimalizowane w próbie estymacyjnej, natomiast jakość prognoz oceniano dodatkowo poza próbą na danych z 2024 r. Dodatkowo, aby ograniczyć ryzyko regresji pozornej wynikające z niestacjonarności części szeregów, przetestowano stacjonarność reszt wybranej specyfikacji (ADF i KPSS), uzyskując wyniki zgodne ze stacjonarnością reszt. Najlepszą specyfikację (o najniższej wartości BIC) stanowi model:

$$y = -273 + 5,35X_3 - 7,28X_5 + 3,72X_7 + 0,11X_{10} + 1,33cena_{-1} - 0,38cena_{-2}$$

W celu prognozowania cen transakcyjnych zastosowano również model sztucznej sieci neuronowej typu MLP (Multi-Layer Perceptron), który stanowi nieliniowe uogólnienie modelu regresyjnego. Model ten pozwala na uchwycenie bardziej złożonych zależności pomiędzy zmiennymi objaśniającymi, a zmienną objaśnianą, w tym nieliniowych efektów reakcji rynku mieszkaniowego na egzogeniczne zmienne makroekonomiczne (Bishop, 1995; Hornik i in., 1989). Zastosowanie sieci jest uzasadnione dynamicznym oraz wieloczynnikowym charakterem rynku oraz możliwością adaptacyjną modelu do zmieniających się warunków gospodarczych (Gupta, Miller, 2012; Lim i in., 2016).

Zastosowana w modelu zmienna objaśniana została wystandaryzowana w postaci przyrostów logarytmicznych $\Delta \log(Y_t) = \log(Y_t) - \log(Y_{t-1})$, co ogranicza heteroskedastyczność oraz umożliwia interpretację w kategoriach procentowych zmian cen (Stock i Watson, 2020; Wooldridge, 2009). Prognozy uzyskane w skali $\Delta \log(Y)$ zostały skonwertowane do poziomu cen transakcyjnych zgodnie z relacją $\hat{Y}_t = Y_{t-1} \cdot e^{\Delta \log(\hat{Y}_t)}$ – co umożliwia porównanie predykcji modelu z rzeczywistą ceną 1 m² na rynku wtórnym (Hamilton, 1994). Do modelu wprowadzono autoregresyjną zmienną pierwszego rzędu (Y_{t-1}), która pozwala modelowi na wykorzystanie informacji o przeszłym poziomie cen. Ponadto, uwzględniono sezonowość cyklu rocznego poprzez wprowadzenie trzech dychotomicznych zmiennych (Q_2, Q_3, Q_4), przy czym pierwszy kwartał stanowi kategorię odniesienia (Harvey, 1981).

Z pełnego zbioru 11 egzogenicznych zmiennych makroekonomicznych zastosowano wieloetapową selekcję, łącząc filtrację statystyczną oraz ocenę informacyjności modeli wstępnych:

1. Standaryzacja częstotliwości danych – wszystkie szeregi przekształcono do częstotliwości kwartalnej (Hamilton, 1994).
2. Utworzono transformacje⁴ (Enders, 2015; Stock, Watson, 2020):
 - $\text{Lag}(X_{t-1})$ – uchwycenie opóźnionych reakcji rynku;
 - $\Delta \log(X_t)$ – zatem $\log(X_t) - \log(X_{t-1})$ – stabilizacja wariancji i interpretacja w kategoriach tempa wzrostu;

⁴ Transformacje lag oraz $\Delta \log$ konstruowano wyłącznie na obserwacjach z okresów wcześniejszych niż prognozowany ($t-1$), co eliminuje ryzyko *look-ahead bias* oraz odzwierciedla rzeczywisty proces podejmowania decyzji w czasie.

3. Filtracja statystyczna (Elisseef i Guyon, 2003; Greene, 2020; Mukaka, 2012):
 - usunięto szeregi o niskiej zmienności;
 - obliczono korelację Pearsona i Spearmana z ceną $\Delta \log(Y)$. Zachowano zmienne dla których $|r| \geq 0,2$;
 - sprawdzono współliniowość poprzez wskaźnik VIF (*Variance Inflation Factor*). W parach o $VIF > 5$ zachowywano zmienną, która wykazywała większą stabilność wpływu w czasie.
4. Ocena informacyjności (Breiman, 2001; Lundberg, Lee, 2017):
 - Gini importance – średnią redukcję nieczystości;
 - istotność permutacji – spadek trafności po losowym permutowaniu zmiennej;
 - wartości SHAP – marginalny wkład zmiennej w predykcję.

Wyniki analiz zostały uporządkowane w formie rankingu i poddane uśrednieniu. Następnie wyłoniono zestaw pięciu zmiennych o najwyższej wartości predykcyjnej, przy jednoczesnym zachowaniu stabilności kierunku wpływu. Ostatecznie do zbioru zmiennych egzogenicznych włączono te, które spełniły oba kryteria w najbardziej zrównoważony sposób:

1. PKB wygenerowane przez budownictwo (mld zł) – lag;
2. mieszkania oddane do użytkowania (tys.) – $\Delta \log$;
3. stopa oprocentowania referencyjna (stan na koniec okresu) – $\Delta \log$;
4. przeciętne miesięczne wynagrodzenie nominalne brutto (zł) – $\Delta \log$;
5. inflacja (%) – $\Delta \log$.

Po wytypowaniu zmiennych objaśniających przystąpiono do doboru struktury sieci i parametrów uczenia. Z uwagi na to, że zmienna objaśniana została przetransformowana do postaci przyrostu logarytmicznego $\Delta \log(Y_t)$ model zwraca prognozę tempa zmian między kolejnymi kwartałami; w przypadku małej próbki obserwacji (40 okresów) istnieje ryzyko predyktowania zbyt gwałtownych zmian pomiędzy okresami, prowadzących do nienaturalnych skoków cen (Enders, 2015; Hamilton, 1994). W celu zapewnienia realizmu dynamiki prognostycznej zastosowano korektę maksymalnej zmiany na poziomie $|\Delta \log(\hat{Y}_t)| \leq 3\%$ na kształt praktyki winsoryzacji; wartość ta została wyznaczona empirycznie, jako maksymalne tempo wzrostu kwartalnego obserwowane w danych historycznych na zbiorze uczącym – zabieg ten stabilizuje

model oraz ogranicza propagację pojedynczych anomalii (Seheult i in., 1989; Wilcox, 2012). Sieć uczona była algorytmem wstecznej propagacji błędu z optymalizatorem Adam z domyślnymi parametrami ($\beta_1 = 0,9$; $\beta_2 = 0,999$) przez 100 epok, co jest szczególnie korzystne w przypadku danych o zmiennym tempie trendu (Kingma i Ba, 2014). Walidacji modelu dokonano za pomocą *expanding-window cross-validation*. Początkowe okno treningowe obejmowało cztery pierwsze obserwacje, a w każdej kolejnej iteracji było rozszerzane o jedną obserwację; dokładność prognozy oceniano dla horyzontu jednookresowego ($t+1$), by uniknąć efektu *look-ahead* (Hyndman, Athanasopoulos, 2021). Jako funkcję aktywacji zastosowano ReLU, która umożliwia modelowi aproksymację nieliniowych zależności przy zachowaniu stabilności obliczeń. Funkcja ReLU jest standardem w modelach MLP ze względu na brak problemu zanikania gradientu charakterystycznego dla funkcji sigmoidalnych (Glorot i in., 2011). W celu doboru optymalnego modelu wykorzystano procedurę *Grid search* na przestrzeni hiperparametrów, która obejmowała (Bergstra, Bengio, 2012):

$$\left\{ \begin{array}{l} \text{warstwy ukryte} \in \{(3,); (4,); (4,2); (6,2)\} \\ \lambda_{L1} \in \{0,01; 0,03; 0,1\} \\ \text{funkcja straty} \in \{"MSE"; "Huber"\} \\ \text{learning rate} \in \{0,001; 0,003\} \\ \text{batch size} \in \{4, 6, 8\} \end{array} \right.$$

Zatem łącznie wzięto pod uwagę 144 modele, a jako kryterium wyboru zastosowano minimalizację błędu walidacyjnego MAPE. W trakcie badania zaobserwowano, że większe architektury ((4,2); 6,2)) prowadziły do przeuczenia objawiającego się niskim błędem na próbie uczącej, lecz wyraźnie pogorszonym błędem walidacyjnym oraz nierealistyczną dynamiką prognoz. Ostatecznie wybrano architekturę: *MLP*(9 → 4 → 1), *ReLU*, *hidden* = (4,), $\lambda_{L1} = 0,03$, *loss* = *Huber*, $\eta = 0,001$, *batch* = 6.

Parametry te zostały wyznaczone jako optymalne w rozumieniu kompromisu pomiędzy zdolnością aproksymacyjną modelu, a jego stabilnością prognostyczną. Funkcja straty Huber okazała się w tym kontekście bardziej odpowiednia niż klasyczny błąd średniokwadratowy (MSE), ponieważ ogranicza wpływ obserwacji odstających na gradient podczas uczenia (Heaton, 2017). Jest to szczególnie istotne w przypadku rynku nieruchomości, gdzie na wartość

wskaźników makroekonomicznych mogą okresowo oddziaływać incydentalne wstrząsy podażowo-popytowe lub jednorazowe zmiany regulacyjne (Siemińska, 2011). Regularyzacja L1 dodatkowo pełniła funkcję *miękkiej selekcji wag*, zapobiegając nadmiernej czułości modelu na zmienne o słabym wpływie. Wybrany model charakteryzuje się 9 wejściami, odpowiadającymi: autoregresji pierwszego rzędu Y_{t-1} , trzem zmiennym sezonowym Q_2, Q_3, Q_4 oraz pięciu zmiennym egzogenicznym opisującym sytuację makroekonomiczną rynku budowlanego. Taka konstrukcja pozwala modelowi jednocześnie uwzględniać zarówno krótkookresową dynamikę inercyjną cen, cykliczność sezonową, jak i wpływ czynników fundamentalnych.

Wyniki

Dane wykorzystane w analizie zostały zestawione w Tabeli 1. Obejmują one okres od I kwartału 2014 r. do IV kwartału 2024 r. Do estymacji modelu wykorzystano dane z pierwszej dekady tego przedziału, tj. od I kwartału 2014 r. do IV kwartału 2023 r. Ostatnie cztery obserwacje (2024 r.) posłużyły do weryfikacji jakości prognoz oraz obliczenia błędów typu *ex ante* i *ex post*. Parametry modelu należy interpretować jako warunkowe zależności predykcyjne w ramach przyjętej specyfikacji dynamicznej, a nie jako efekty przyczynowe.

Dla zmiennych w modelu oznacza to:

- wzrost liczby mieszkań, na realizację których wydano pozwolenia lub dokonano zgłoszenia z projektem budowlanym (X3) o 1 tys. jednostek jest związany ze wzrostem prognozowanej średniej ceny 1 m² o ok. 5,35 zł;
- wzrost liczby mieszkań oddanych do użytkowania (X5) o 1 tys. jednostek jest związany ze spadkiem prognozowanej średniej ceny 1 m² o ok. 7,28 zł;
- wzrost PKB wytworzonego przez budownictwo (X7) o 1 jednostkę (zgodnie z jednostką w danych) jest związany ze wzrostem prognozowanej średniej ceny 1 m² o ok. 3,72 zł;
- wzrost przeciętnego nominalnego miesięcznego wynagrodzenia brutto (X10) o 1 zł jest związany ze wzrostem prognozowanej średniej ceny 1 m² o ok. 0,11 zł;

- współczynniki przy $cena_{-1}$; $cena_{-2}$ potwierdzają istotną inercję procesu cenowego: wartość bieżąca jest w znacznym stopniu determinowana przez poziom cen w dwóch poprzednich kwartałach.

Stworzony model został wykorzystany do predykcji średnich cen nieruchomości na rynku wtórnym dla 16 miast wojewódzkich w Polsce w czterech kwartałach 2024 r. (Tabela 2).

Tabela 1. Dane wykorzystane do modelu

Czas	Cena za m ²	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	X ₁₀	X ₁₁
I 2014	4305,36	16279,00	7118,80	34,80	32,20	35,60	2,50	19391,00	408,60	13,50	3895,31	0,60
II 2014	4353,91	40834,70	17627,80	41,90	40,00	30,90	2,50	29962,00	410,30	12,00	3739,97	0,30
III 2014	4395,25	69060,80	30039,60	43,80	42,30	33,70	2,00	35884,30	410,30	11,50	3781,14	-0,30
IV 2014	4377,21	101908,80	48985,50	36,50	33,60	43,00	2,00	41269,20	416,90	11,40	3942,67	-0,70
I 2015	4382,60	17772,40	8217,80	38,60	31,80	31,70	1,50	21853,80	383,70	11,50	4054,89	-1,50
II 2015	4381,84	41964,50	20034,30	48,60	48,50	32,30	1,50	33102,20	382,90	10,20	3854,88	-0,90
III 2015	4431,32	70499,30	34023,10	51,20	47,70	37,40	1,50	39213,40	389,30	9,70	3895,33	-0,70
IV 2015	4415,74	105919,70	53633,00	50,40	40,30	46,40	1,50	47474,80	394,50	9,70	4066,95	-0,60
I 2016	4425,82	16125,00	7241,80	42,70	34,30	37,40	1,50	20931,70	382,50	9,90	4181,49	-0,90
II 2016	4460,69	40284,10	16962,00	55,60	52,00	36,30	1,50	32111,10	384,00	8,70	4019,08	-0,90
III 2016	4498,84	65243,30	27823,60	56,20	46,80	38,30	1,50	34801,90	383,00	8,30	4055,04	-0,80
IV 2016	4540,22	94447,10	42659,30	57,00	40,80	51,30	1,50	44083,60	391,20	8,20	4218,92	0,20
I 2017	4535,49	16718,10	6455,60	60,70	44,20	40,50	1,50	19629,90	382,60	8,00	4353,55	2,00
II 2017	4673,72	41408,60	15469,90	70,60	61,80	37,80	1,50	32295,00	382,20	7,00	4220,69	1,80
III 2017	4772,84	69313,50	26189,10	59,60	54,80	45,90	1,50	37831,30	389,50	6,80	4255,59	1,90
IV 2017	4830,63	102769,70	43758,90	60,00	45,10	54,10	1,50	44048,60	401,40	6,60	4516,69	2,20
I 2018	4914,05	20019,10	7239,20	66,60	48,00	44,60	1,50	24624,80	399,90	6,60	4622,84	1,50
II 2018	5064,94	48485,70	18191,50	65,60	65,70	38,20	1,50	39032,50	405,10	5,80	4521,08	1,70
III 2018	5237,41	80641,30	31388,20	61,80	60,30	47,00	1,50	43881,00	413,90	5,70	4580,20	2,00
IV 2018	5362,68	117197,40	51831,60	63,60	47,90	55,30	1,50	50902,80	419,60	5,80	4863,74	1,40
I 2019	5472,61	19841,70	9955,00	57,30	53,90	47,40	1,50	27625,80	422,10	5,90	4950,94	1,20
II 2019	5676,53	50835,40	23321,70	72,30	61,50	47,10	1,50	42539,90	423,60	5,30	4839,24	2,40

Czas	Cena za m ²	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	X ₁₀	X ₁₁
III 2019	5828,08	84533,80	37945,40	71,80	63,10	51,20	1,50	47373,60	424,40	5,10	4931,59	2,80
IV 2019	6026,11	121185,70	61162,10	67,40	58,80	61,70	1,50	52346,60	432,60	5,20	5198,58	2,80
I 2020	6212,91	22334,70	11569,70	59,40	52,50	49,60	1,00	30195,40	426,10	5,40	5331,47	4,50
II 2020	6445,40	51898,70	24348,00	62,90	47,40	47,50	0,10	43278,60	429,90	6,10	5024,48	3,20
III 2020	6498,41	82396,80	37645,90	70,10	67,40	59,20	0,10	44192,70	421,50	6,10	5168,93	3,00
IV 2020	6651,32	119187,90	57507,80	83,70	56,50	64,60	0,10	50551,60	427,90	6,80	5457,98	2,80
I 2021	6732,27	23863,80	10925,60	84,80	63,70	53,10	0,10	24376,90	419,60	6,90	5681,56	2,70
II 2021	6985,95	55900,00	24208,70	87,10	80,90	52,40	0,10	43689,70	425,40	6,40	5504,52	4,50
III 2021	7187,19	90962,80	40093,50	83,50	71,80	58,70	0,10	44717,30	422,30	6,10	5657,30	5,40
IV 2021	7456,13	144971,30	63667,80	85,80	61,10	70,60	1,75	49548,50	430,30	5,80	5995,09	7,70
I 2022	7734,93	28377,30	12112,40	78,00	53,30	54,70	3,50	29134,20	423,70	5,80	6235,22	9,70
II 2022	8070,09	70158,90	29181,10	93,40	66,40	54,50	6,00	48015,30	425,40	5,20	6156,25	13,90
III 2022	8248,52	113042,60	48352,40	66,20	45,10	57,80	6,75	48077,80	435,90	5,10	6480,67	16,30
IV 2022	8209,61	165226,90	76320,40	60,70	35,50	71,50	6,75	55878,40	449,80	5,20	6733,49	17,30
I 2023	8167,47	34387,70	14346,90	52,10	38,60	55,10	6,75	33783,10	417,20	5,40	7124,26	17,00
II 2023	8349,56	78337,70	33261,90	60,00	47,00	56,80	6,75	57409,40	423,60	5,10	7005,76	13,10
III 2023	8672,71	123855,30	55179,80	62,30	53,30	49,00	6,00	54555,60	422,70	5,00	7194,95	9,70
IV 2023	8965,75	179730,90	86175,10	67,30	50,20	60,40	5,75	66893,20	429,80	5,10	7540,36	6,40
I 2024	9419,38	32351,50	13239,20	70,00	60,10	48,40	5,75	33927,50	415,3	5,30	8147,38	2,80
II 2024	9918,43	75222,30	31092,10	74,20	62,30	47,20	5,75	57768,40	415,1	4,90	8038,41	2,50
III 2024	10221,11	120528,50	50451,70	76,30	59,10	49,40	5,75	56933,40	425,8	5,00	8161,62	4,50
IV 2024	10222,81	176824,10	79131,20	71,20	52,30	55,10	5,75	68195,70	430,2	5,10	8477,21	4,80

Źródło: opracowanie własne na podstawie: Kwartalne wskaźniki cen towarów i usług konsumpcyjnych od 1995 r. (GUS), Kwartalne wskaźniki makroekonomiczne (GUS), Baza cen nieruchomości mieszkaniowych (NBP).

Tabela 2. Prognoza średnich cen nieruchomości na rynku wtórnym dla 16 miast wojewódzkich w Polsce w 2024 r. wraz z błędami *ex ante*

Kwartał	Cena za m ²	Prognoza	Błąd <i>ex ante</i>	95% przedział predykcji
I 2024	9419,38	9322,98	56,66	9207,42-9438,54
II 2024	9918,43	9792,87	94,11	9600,92-9984,82
III 2024	10221,10	10284,67	122,22	10035,41-10533,93
IV 2024	10222,80	10764,15	143,21	10472,08-11056,22


Źródło: opracowanie własne z wykorzystaniem programu R.

W analizowanym przypadku wartości błędu typu *ex ante* dla czterech prognozowanych kwartałów roku 2024 wykazują tendencję rosnącą (od 56,66 do 143,21), co odzwierciedla wzrost niepewności prognoz wraz z wydłużaniem horyzontu od ostatniego okresu estymacji (IV kwartał 2023 r.). Jest to zjawisko typowe dla modeli szeregów czasowych z komponentem autoregresyjnym: w prognozie dynamicznej kolejne wartości prognozowane wykorzystują wcześniejsze prognozy jako zmienne opóźnione, co prowadzi do kumulacji niepewności w horyzoncie wielookresowym. Wartości *ex ante* interpretowane są jako odchylenie standardowe błędu prognozy, wyznaczone na podstawie oszacowanej wariancji składnika losowego oraz parametrów części autoregresyjnej AR(2). Na tej podstawie skonstruowano 95% przedziały predykcji dla prognoz na 2024 r., które – przy przyjętych założeniach modelu – powinny w długim okresie obejmować rzeczywistą wartość zmiennej w ok. 95% przypadków.

W ocenie wiarygodności prognoz istotne znaczenie mają błędy *ex post*, które umożliwiają porównanie jakości predykcyjnej modelu regresji dynamicznej (AR(2)-X) z alternatywnymi podejściami, w tym modelami opartymi na sieciach neuronowych. Obliczenie miar ME, MAE, MPE i MAPE stanowi standardowy element weryfikacji jakości prognoz (Rogalska, 2018). Miary wyznaczono na podstawie prognoz poza próbą dla czterech kwartałów 2024 r.

Średni błąd prognozy (ME) wyniósł -95,730 zł/m². Ujemna wartość ME oznacza, że model wykazywał przeciętną tendencję do przeszacowywania poziomu cen – prognozy były średnio wyższe od wartości rzeczywistych o ok. 95,73 zł/m². Średni błąd bezwzględny (MAE) osiągnął poziom 206,710 zł/m², co wskazuje, że przeciętne odchylenie prognoz od obserwacji wynosiło ok. 206,71 zł/m². Średni błąd procentowy (MPE) wyniósł -0,907%, co również potwierdza niewielkie przeszacowanie prognoz w ujęciu względnym. Z kolei

średni absolutny błąd procentowy (MAPE) równy 2,052% oznacza, że przeciętne prognozy różniły się od wartości rzeczywistych o ok. 2,05% (Rysunek 1).



Rysunek 1. Rzeczywiste i prognozowane średnie ceny transakcyjne 1 m² na rynku wtórnym w Polsce w latach 2014-2024

Źródło: opracowanie własne z wykorzystaniem programu R.

Podsumowując, uzyskane miary wskazują na relatywnie wysoką dokładność prognoz krótkookresowych w analizowanym horyzoncie (2024 r.). Należy jednak podkreślić, że ocena oparta jest na czterech obserwacjach poza próbą, co ogranicza możliwość uogólnienia wniosków; dlatego miary błędu należy interpretować jako ocenę jakości predykcji w krótkim, jednorocznym oknie walidacyjnym.

Dla sieci neuronowych wykorzystano te same dane wejściowe co dla modelu regresji liniowej, a prognozy cen transakcyjnych na rynku wtórnym w 16 miastach wojewódzkich dla czterech kwartałów 2024 r. przedstawiono poniżej (Tabela 3).


Tabela 3. Prognoza średnich cen nieruchomości wg modelu MLP oraz błędy *ex post*

Kwartał	Cena rzeczywista	Prognoza	Error	%APE
31.03.2024	9419,38	9149,51	269,87	2,87
30.06.2024	9918,43	9612,44	305,99	3,09
30.09.2024	10221,11	10121,72	99,39	0,97
31.12.2024	10222,81	10430,60	-207,79	2,03

Źródło: opracowanie własne z wykorzystaniem biblioteki scikit-learn oraz tensorflow.

W analizowanym przypadku wartości błędów prognozy w poszczególnych kwartałach roku 2024 mieszczą się w przedziale od 0,97% do 3,09%, co świadczy o stosunkowo stabilnej dokładności modelu w horyzoncie krótkookresowym. Najwyższe wartości błędu (%APE) wystąpiły w I i II kwartale 2024 r., czyli w okresie przyspieszenia dynamiki cen mieszkań. Jest to zgodne z obserwacją, że nieliniowe modele uczone na krótkim szeregu mogą reagować z opóźnieniem na nagłe zmiany trendu (Heaton, 2017). Od III kwartału dokładność prognozy ulega poprawie, a w IV kwartale model zachowuje poprawną trajektorię cen, choć obserwuje się niewielkie przeszacowanie poziomu cen, czego odzwierciedleniem jest ujemny błąd ME w ostatnim okresie.

Do analizy zastosowano standardowe miary: ME, MAE, MPE oraz MAPE. Średni błąd prognozy (ME) wyniósł 116,87, co oznacza niewielką tendencję modelu do niedoszacowania cen prognozowane wartości były średnio niższe od rzeczywistych o 116,87 zł/m². Średni błąd bezwzględny (MAE) osiągnął poziom 220,76zł/m², co wskazuje, że przeciętne odchylenie prognoz od cen rzeczywistych wyniosło 220,76 zł/m². Średni błąd procentowy (MPE) równy 1,22 potwierdza występowanie niewielkiego systematycznego niedoszacowania, rzędu 1,22%. Z kolei średni absolutny błąd procentowy (MAPE) wyniósł 2,24%, co oznacza, że przeciętnie prognozy odbiegały od wartości rzeczywistych o 2,24%. Zgodnie z klasyfikacją stosowaną w badaniach prognostycznych, wartości $1\% < \text{MAPE} \leq 3\%$ interpretowane są jako prognozy wysokiej dokładności (Rogalska, 2018) (Rysunek 2).



Rysunek 2. Rzeczywista i prognozowana zmiana cen nieruchomości – sieci neuronowe
Źródło: opracowanie własne z wykorzystaniem programu Excel.

Osiągnięte błędy *ex post* mieszczą się w zakresie uznawanym za akceptowalny dla prognoz rynku nieruchomości, co potwierdza użyteczność modelu w zastosowaniach praktycznych.

Wnioski

Przeprowadzone badanie miało na celu porównanie skuteczności prognozowania cen nieruchomości mieszkaniowych w Polsce z wykorzystaniem modelu regresji dynamicznej typu AR(2)-X estymowanego metodą najmniejszych kwadratów oraz sztucznych sieci neuronowych. Analiza oparta została na danych GUS dotyczących średnich kwartalnych cen transakcyjnych za 1 m² na rynku wtórnym w 16 miastach wojewódzkich w latach 2014-2024.

Wyniki wskazują na nieznaczną przewagę modelu regresji dynamicznej typu AR(2)-X w zakresie dokładności prognoz krótkookresowych w analizowanym oknie walidacyjnym. Dla prognoz poza próbą (2024Q1-2024Q4) uzyskano MAPE = 2,05% oraz MAE = 206,71 zł/m². Jednocześnie odnotowano ujemny ME = -95,73 zł/m² oraz MPE = -0,91%, co oznacza niewielką przeciętną tendencję modelu do przeszacowywania poziomu cen (prognozy średnio nieco przewyższały wartości obserwowane). Istotną zaletą podejścia regresyjnego jest możliwość jawnego wyznaczania 95% przedziałów predykcji

dla prognoz *ex ante*, co pozwala oceniać niepewność prognoz w sposób spójny z założeniami modelu.

Model sieci neuronowej (MLP), pomimo zastosowania zaawansowanych technik regularyzacji i walidacji kroczącej, osiągnął gorsze rezultaty: średni absolutny błąd procentowy (MAPE) osiągnął poziom 2,24%, natomiast średni błąd bezwzględny (MAE) wyniósł 220,76. Różnice między metodami są umiarkowane, jednak w analizowanym przypadku wskazują na lepszą kalibrację progностyczną modelu regresji dynamicznej.

Gorsze wyniki sieci neuronowej można przypisać kilku czynnikom, w tym ograniczonej wielkości próby, obejmującej 40 obserwacji kwartalnych. Ponadto, względna prostota zależności w badanym zbiorze danych mogła nie wymagać zaawansowanego modelowania nieliniowego, co uwidoczniło przewagę prostszych modeli liniowych w kontekście dokładności progностycznej.

Otrzymane wyniki wskazują, że w przypadku niewielkich i stabilnych zbiorów danych tradycyjne modele liniowe mogą osiągać porównywalną lub nawet wyższą dokładność progностyczną niż sieci neuronowe. Jednocześnie większe możliwości uogólniania charakterystyczne dla ANN mogą ujawniać się dopiero przy większej liczbie obserwacji oraz bardziej złożonej strukturze relacji. W takich sytuacjach uzasadnione może być podejście hybrydowe, które łączy stabilność modeli regresyjnych z elastycznością nieliniowego modelowania sieciowego.

Ograniczenia i przyszłe badania

Przeprowadzone badanie charakteryzuje się następującymi ograniczeniami, które mogą wpływać na interpretację i generalizację wyników. Po pierwsze, ograniczony zakres czasowy analizy, obejmujący dane z lat 2014-2024, może nie odzwierciedlać pełnego spektrum długoterminowych cykli koniunkturalnych i strukturalnych na rynku nieruchomości. Dłuższy horyzont czasowy pozwoliłby na lepsze uchwycenie zmienności i dynamiki tego złożonego segmentu gospodarki w Polsce.

Po drugie, agregacja danych do poziomu 16 miast wojewódzkich może ograniczać dokładność analizy, ponieważ ceny i czynniki wpływające na nie mogą znacznie różnić się w zależności od konkretnej lokalizacji.

Po trzecie, model sztucznych sieci neuronowych (MLP) został zbudowany na podstawie ograniczonej wielkości próby, obejmującej 40 obserwacji

kwartalnych. Jest to często niewystarczające dla pełnego wykorzystania potencjału nieliniowych modeli uczenia maszynowego, które uczą się najlepiej, gdy mają dostęp do tzw. dużych zbiorów danych. Mimo zastosowania technik przeciwdziałających przeuczeniu, takich jak standaryzacja cech, regularyzacja L1, wczesne zatrzymanie treningu i redukcja współczynnika uczenia, mała próba mogła ograniczyć zdolność ANN do modelowania złożonych zależności i optymalizacji hiperparametrów.

Dodatkowo, należy pamiętać, że sieci neuronowe są często określane mianem „czarnych skrzynek”, ponieważ ich działanie i proces podejmowania decyzji mogą być trudne do odczytania i zrozumienia. Jest to istotne ograniczenie, szczególnie w kontekście podejmowania decyzji, gdzie cenna jest możliwość analizy przyczynowo-skutkowej.

W przypadku modelu regresji dynamicznej AR(2)-X, dla czterech prognozowanych kwartałów 2024 roku, wartości błędu typu *ex ante* wykazywały tendencję rosnącą, od 56,66 do 143,21. Ilustruje to stopniowy wzrost niepewności prognozy wraz z oddalaniem się od ostatniego okresu estymacji.

Literatura

1. Aguinis, H., Beaty, J. C., Boik, R. J., Pierce, C. A. (2005). Effect size and power in assessing moderating effects of categorical variables using multiple regression: a 30-year review. *Journal of Applied Psychology*, 90(1), 94-107. <https://doi.org/10.1037/0021-9010.90.1.94>.
2. Ampuła, D. (2014). Regresja jako metoda procesu predykcji. *Problemy Techniki Uzbrojenia*, 130(2), 67-78.
3. Baum, C. F., Lewbel, A. (2019). Advice on using heteroskedasticity-based identification. *The Stata Journal: Promoting Communications on Statistics and Stata*, 19(4), 757-767. <https://doi.org/10.1177/1536867X19893614>
4. Bergstra, J., Bengio, Y. (2012). Random search for hyper-parameter optimization. *The Journal of Machine Learning Research*, 13(1), 281-305.
5. Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. Oxford University Press. <https://doi.org/10.1093/oso/9780198538493.001.0001>
6. Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>

7. Bryx, M. (2006). Zarządzanie nieruchomością jako faza procesu inwestycyjnego. *Studia i Materiały Towarzystwa Naukowego Nieruchomości*, 14(1), 27-34.
8. Cattaneo, M. D., Jansson, M., Newey, W. K. (2018). Inference in linear regression models with many covariates and heteroscedasticity. *Journal of the American Statistical Association*, 113(523), 1350-1361. <https://doi.org/10.1080/01621459.2017.1328360>
9. Chicco, D., Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21(6), 1-13. <https://doi.org/10.1186/s12864-019-6413-7>
10. Elisseeff, A., Guyon, I. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3, 1157-1182.
11. Enders, W. (2015). *Applied econometric time series* (4. edycja). Wiley.
12. Fernandes, A.C.P., Fonseca, A., Pacheco, F., Sanchez Fernandez, L. F. (2023). Water quality predictions through linear regression – a brute force algorithm approach. *MethodsX*, 10, s102153. <https://doi.org/10.1016/j.mex.2023.102153>
13. Flores Hinostroza, E. M., Mendoza, D. J., Navarro Cejas, M., Palacios Trujillo, E. P. (2025). Linear regression model to predict the use of artificial intelligence in experimental science students. *International Electronic Journal of Mathematics Education*, 20(1), em0807. <https://doi.org/10.29333/iejme/15736>.
14. Ghouse, G., Khan, S.A., Rehman, A.U. (2018). ARDL model as a remedy for spurious regression problems, performance and prospectus. *Munich Personal RePEc Archive*, 83973.
15. Glorot, X., Bordes, A., Bengio, Y. (2011). Deep sparse rectifier neural networks. W: *Proceedings of the fourteenth international conference on artificial intelligence and statistics* (s. 315-323). PMLR.
16. Gołabeska, E. (2011). Efektywność inwestowania na rynku nieruchomości przy uwzględnieniu ryzyka. *Studia i Prace Kolegium Zarządzania i Finansów / Szkoła Główna Handlowa*, 110, 9-22.
17. Gorriz, J. M., Ramirez, J., Segovia, F., Jimenez-Mesa, C., Martinez-Murcia, F. J., Suckling, J. (2026). Statistical agnostic regression: a machine learning method to validate regression models. *Journal of Advanced Research*, 80, 503-533. <https://doi.org/10.1016/j.jare.2025.04.026>

18. Grzywińska-Rapca, M., Andruszkiewicz, K., Grzybowska-Brzezińska, M., Oktaba, P. (2024). *Determinanty preferencji klientów a perspektywa rozwoju rynku nieruchomości mieszkaniowych w Polsce*. Wydawnictwo Ostrołęckiego Towarzystwa Naukowego im. Adama Chętnika.
19. Greene, W. (2020). *Econometric analysis* (8th edition, global edition). Pearson.
20. Gupta, R., Miller, S. M. (2012). The time-series properties of house prices: a case study of the Southern California market. *The Journal of Real Estate Finance and Economics*, 44(3), 339-361. <https://doi.org/10.1007/s11146-010-9234-7>
21. Hamilton, J. D. (1994). *Time series analysis*. Princeton University Press. <https://doi.org/10.1515/9780691218632>
22. Harvey, A. C. (1981). *The econometric analysis of time series*. Wiley.
23. Haykin, S. (2009). *Neural Networks and Learning Machines*. 3. edycja. Prentice Hall.
24. Hazimeh, H., Mazumder, R. (2020). Fast best subset selection: coordinate descent and local combinatorial optimization algorithms. *Operations Research*, 68(5), 1517-1537. <https://doi.org/10.1287/opre.2019.1919>
25. Heaton, J. (2017). Ian Goodfellow, Yoshua Bengio, and Aaron Courville: deep learning. *Genetic Programming and Evolvable Machines*, 19(1-2), 305-307. <https://doi.org/10.1007/s10710-017-9314-z>
26. Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4(2), 251-257. [https://doi.org/10.1016/0893-6080\(91\)90009-T](https://doi.org/10.1016/0893-6080(91)90009-T)
27. Hornik, K., Stinchcombe, M., White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359-366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
28. Hyndman, R. J., Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3. edycja). Otexts, Online Open-Access Textbooks.
29. Kingma, D. P., Ba, J. (2014). Adam: a method for stochastic optimization. *arXiv*, 1412.6980. <https://doi.org/10.48550/ARXIV.1412.6980>
30. Kucharska-Stasiak, E. (2005). *Podstawy funkcjonowania rynku nieruchomości – ujęcie teoretyczne*. Wydawnictwo Uniwersytetu Łódzkiego.
31. LeCun, Y., Bengio, Y., Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>

32. Lim, W. T., Wang, L., Wang, Y., Chang, Q. (2016). Housing price prediction using neural networks. W: *2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)* (s. 518-522). IEEE. <https://doi.org/10.1109/FSKD.2016.7603227>
33. Lipton, Z. C. (2018). The mythos of model interpretability. *Communications of the ACM (CACM)*, 61(10), 36-43. <https://doi.org/10.1145/3233231>
34. Lundberg, S., Lee, S.-I. (2017). A unified approach to interpreting model predictions. *arXiv*, 1705.07874. <https://doi.org/10.48550/ARXIV.1705.07874>
35. Mach, Ł. (2014). Czynniki kształtujące wartość nieruchomości mieszkaniowych w kontekście uwarunkowań makro-, mikro- oraz ultraotoczenia. *Ekonometria*, 46(4), 52-61. <https://doi.org/10.15611/ekt.2014.4.05>
36. Mondal, S., Maity, R., Nag, A. (2025). An efficient artificial neural network-based optimization techniques for the early prediction of coronary heart disease: Comprehensive analysis. *Scientific Reports*, 15(1), 4827. <https://doi.org/10.1038/s41598-025-85765-x>
37. Mukaka, M. M. (2012). Statistics corner: a guide to appropriate use of correlation coefficient in medical research. *Malawi Medical Journal: The Journal of Medical Association of Malawi*, 24(3), 69-71.
38. Pires, P. B., Santos, J. D., Pereira, I. V. (2023). Artificial Neural Networks: history and state of the art. W: *Encyclopedia of Information Science and Technology, Sixth Edition*. IGI Global. <https://doi.org/10.4018/978-1-6684-7366-5.ch037>
39. Poole, M. A., O'Farrell, P. N. (1971). The assumptions of the linear regression model. *Transactions of the Institute of British Geographers*, 52, 145-158.
40. Puchalski, J., Warsza, Z. (2022). Regression and uncertainty of a straight-line for measurements of x and y variables with all correlations. *Pomiary Automatyka Robotyka*, 26(2), 47-58. https://doi.org/10.14313/PAR_244/47
41. Qamar, R., Zardari, B. A. (2023). Artificial Neural Networks: an overview. *Mesopotamian Journal of Computer Science*, 2023, 130-139. <https://doi.org/10.58496/MJCSC/2023/015>
42. Rogalska, M. (2018). Wycena nieruchomości z wykorzystaniem metody wieloczynnikowych modeli statystycznych. W: A. Sobotka, E. Radziszewska-Zielina (red.), *Inżynieria przedsięwzięć budowlanych: problemy, modele, metody* (s. 257-290). Komitet Inżynierii Lądowej i Wodnej PAN.

43. Sarkodie, S. A., Owusu, P. A. (2020). How to apply the novel dynamic ARDL simulations (dynardl) and Kernel-based regularized least squares (krls). *MethodsX*, 7, 101160. <https://doi.org/10.1016/j.mex.2020.101160>
44. Schmidhuber, J. (2015). Deep learning in neural networks: an overview. *Neural Networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
45. Seheult, A. H., Green, P. J., Rousseeuw, P. J., Leroy, A. M. (1989). Robust regression and outlier detection. *Journal of the Royal Statistical Society. Series A (Statistics in Society)*, 152(1), 133. <https://doi.org/10.2307/2982847>
46. Siemińska, E. (2011). *Inwestowanie na rynku nieruchomości*. Poltext.
47. Silhavy, R., Silhavy, P., Prokopova, Z. (2017). Analysis and selection of a regression model for the Use Case Points method using a stepwise approach. *The Journal of Systems and Software*, 125, 1-14. <https://doi.org/10.1016/j.jss.2016.11.029>
48. Stock, J. H., Watson, M. W. (2020). *Introduction to econometrics* (4th edition, global edition). Pearson.
49. Vakhshouri, B., Nejadi, S. (2015). Prediction of compressive strength in Light-Weight Self-Compacting Concrete by ANFIS Analytical Model. *Archives of Civil Engineering*, 61(2), 53-72. <https://doi.org/10.1515/ace-2015-0014>.
50. Warsza, Z., Puchalski, J. (2020a). Uncertainty of measurement in the linear regression method. Part 1. Straight-line and its uncertainty bands for uncorrelated measurement data. *Pomiary Automatyka Robotyka*, 24(3), 79-91. https://doi.org/10.14313/PAR_237/79
51. Warsza, Z., Puchalski, J. (2020b). Uncertainty of measurement in the linear regression method part 2. Uncertainty bands of the regression straight-line for the correlated data of y variable. *Pomiary Automatyka Robotyka*, 24(4), 61-72. https://doi.org/10.14313/PAR_238/61
52. Warsza, Z. L., Puchalski, J. (2020c). Estimation of uncertainties in indirect multivariable measurements: Part 1. Case of correlated quantities. W: R. Szweczyk, C. Zieliński, M. Kaliczyńska (red.), *Automation 2020: Towards Industry of the Future* (T. 1140, s. 309-325). Springer International Publishing. https://doi.org/10.1007/978-3-030-40971-5_29
53. Welc, J. (2009). Regresja liniowa jako narzędzie szacowania fundamentalnych współczynników beta na przykładzie spółek giełdowych z sektora maszyn przemysłowych. *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu*, nr 65, 213-223.

54. Wilcox, R. R. (red.). (2012). *Introduction to robust estimation and hypothesis testing* (3rd edition). Academic Press. <https://doi.org/10.1016/B978-0-12-386983-8.00001-9>
55. Wooldridge, J. M. (2009). *Introductory econometrics: A modern approach* (4th edition). South-Western.
56. Zapf, A., Wiessner, C., König, I. R. (2024). Regression analyses and their particularities in observational studies. *Deutsches Ärzteblatt International*, 121, 128-134. <https://doi.org/10.3238/arztebl.m2023.0278>
57. Żróbek, S., Renigier-Biłozor, M., Żróbek, R. (2024). From administrative price to market value of real estate. The evolution of the valuation system in Poland. *Real Estate Management and Valuation*, 3, 127-142. <https://doi.org/10.2478/remav-2024-0030>
58. Zydrón, A., Walkowiak, R. (2013). Analiza atrybutów wpływających na wartość nieruchomości niezabudowanych przeznaczonych na cele budowlane w gminie Mosina. *Rocznik Ochrona Środowiska*, 15, 2911-2924.

Martyna Wróbel¹

Politechnika Opolska

dr inż. Wiktor Sędkowski²

Politechnika Opolska; Nokia

PRZEGLĄD TECHNIK HASZOWANIA W ZABEZPIECZANIU MODELI AI I ROZPOZNAWANIU ATAKÓW TYPU DATA POISONING PRZY UŻYCIU DETEKCJI KOLIZJI HASZY

OVERVIEW OF HASHING TECHNIQUES FOR SECURING AI MODELS AND RECOGNIZING DATA POISONING ATTACKS USING HASH COLLISION DETECTION

Streszczenie

Praca koncentruje się na bezpieczeństwie modeli sztucznej inteligencji (AI) oraz wykorzystaniu funkcji skrótu do ochrony integralności danych treningowych przed atakami typu *data poisoning*. Modele AI, szczególnie w zastosowaniach krytycznych, są narażone na manipulacje danymi, które mogą prowadzić do błędnych decyzji systemu. Funkcje skrótu, takie jak SHA-256 czy BLAKE2, pozwalają wykrywać nawet

¹ <https://orcid.org/0009-0003-5382-314X>, e-mail: ma.wrobel@student.po.edu.pl

² <https://orcid.org/0000-0002-4543-0499>, e-mail: w.sedkowski@po.edu.pl

Wróbel, M., Sędkowski, W. (2026). Przegląd technik haszowania w zabezpieczaniu modeli AI i rozpoznawaniu ataków typu data poisoning przy użyciu detekcji kolizji haszy. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 161-180). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_9

minimalne zmiany w danych, dzięki czemu stanowią ważny element systemów zabezpieczeń. W badaniach porównano wydajność algorytmów MD5, SHA-1, SHA-256, BLAKE2 i bcrypt w językach Python i Rust, analizując zależność między szybkością a poziomem bezpieczeństwa. Wyniki pokazały, że lekkie algorytmy działają błyskawicznie, lecz są mniej odporne, natomiast bcrypt – mimo większych opóźnień – oferuje najwyższy poziom ochrony haseł. Wnioski podkreślają konieczność stosowania silnych funkcji skrótu do weryfikacji integralności danych oraz adaptacyjnych algorytmów (np. bcrypt) w systemach przechowujących dane wrażliwe.

Słowa kluczowe: cyberbezpieczeństwo, kryptografia, sztuczna inteligencja (AI), modele AI

Abstract

The study focuses on AI model security and the use of hash functions to protect the integrity of training data against *data poisoning* attacks. AI models, especially in critical applications, are exposed to data manipulation that can lead to incorrect or harmful system behavior. Hash functions such as SHA-256 and BLAKE2 can detect even minimal data alterations, making them key elements of security systems. The research compared the performance of MD5, SHA-1, SHA-256, BLAKE2, and bcrypt implemented in Python and Rust, analyzing the relationship between speed and security. Results showed that lightweight algorithms are extremely fast but less secure, while bcrypt – though slower – provides strong password protection. The conclusions emphasize the importance of using robust hash functions for data integrity and adaptive algorithms (like bcrypt) for safeguarding sensitive information.

Keywords: cybersecurity, cryptography, artificial intelligence (AI), AI models

Wstęp

Zabezpieczanie modeli sztucznej inteligencji (AI) stanowi jedno z ważniejszych wyzwań w obszarze systemów autonomicznych i analitycznych, zwłaszcza wobec faktu, że ich wykorzystanie ma coraz większe znaczenie w sektorach takich jak medycyna, transport, finanse czy infrastruktura krytyczna (Biggio, Roli, 2018). W przypadku uczenia maszynowego, bezpieczeństwo nie ogranicza się jedynie do ochrony kodu czy fizycznej infrastruktury, ale obejmuje przede wszystkim zapewnienie integralności wykorzystywanych danych oraz odporności modeli na celowe manipulacje, czego wyrazem są liczne podatności ujawnione w ostatnich latach.

Modele AI mogą być podatne na rozmaite typy ataków, z których jednym z najbardziej rozpoznawalnych jest *data poisoning* – zjawisko polegające na celowym wprowadzeniu złośliwych próbek do zbioru treningowego w taki sposób, by wytrenowany model działał niezgodnie z oczekiwaniami w określonym scenariuszu. Typowym przykładem są ataki skierowane na systemy rozpoznawania obrazów, gdzie niewielka liczba zmanipulowanych przykładów w zbiorze uczącym może całkowicie zmienić kategoryzację istotnych obiektów – np. w przypadku systemów automatycznego rozpoznawania znaków drogowych udało się wykazać, że wystarczy zmienić kilka pikseli w obrazie, by model błędnie rozpoznawał znak „Stop” jako „Ograniczenie prędkości” (Gu i in., 2017).

Inny rodzaj zagrożeń stanowią ataki typu *adversarial*, polegające na niewielkich, często niedostrzegalnych modyfikacjach sygnału wejściowego, które powodują błędne działanie modelu, nawet jeśli został wytrenowany na poprawnych danych. W literaturze naukowej wykazano, że głębokie sieci neuronowe mogą być nie tylko podatne na ataki ukierunkowane, ale też odtwarzalne w różnych środowiskach i warstwach sprzętowych (Kurakin i in., 2017). W sferze NLP (przetwarzania języka naturalnego) problem stanowią tzw. *backdoored models*, czyli modele z wszczepionym „tylnym wejściem”, działające poprawnie w normalnych warunkach, lecz po wykryciu określonego wzorca w danych wejściowych generujące złośliwe lub błędne wyjścia.

Wspomniane zagrożenia występują zarówno w modelach klasyfikacji obrazów, jak i przetwarzania tekstu czy systemach rekomendacyjnych, co podkreśla uniwersalność problemu bezpieczeństwa AI. W odpowiedzi na te zagrożenia opracowywane są zaawansowane procedury kontroli integralności danych, w których to funkcje skrótu odgrywają istotną rolę – umożliwiają szybkie wykrycie nieautoryzowanych zmian w zbiorach danych lub parametrach modeli, stanowiąc podstawowy element procesu hardeningu infrastruktury uczenia maszynowego.

Podstawy teoretyczne funkcji skrótu

Funkcja skrótu (ang. *hash function*) to specjalny rodzaj funkcji matematycznej przekształcającej dane wejściowe dowolnej długości w ciąg o ustalonej, zwykle krótkiej długości, zwany skrótem lub haszem. Kluczową cechą

funkcji skrótu jest to, że dowolne, nawet bardzo długie dane źródłowe, takie jak plik czy ciąg znaków, są mapowane na stałej długości ciąg bitów, co umożliwia efektywne porównywanie i weryfikację integralności informacji (Stallings, 2017).

Podstawowe właściwości funkcji skrótu, które warunkują jej użyteczność w zastosowaniach kryptograficznych i bezpieczeństwa, to: jednokierunkowość, odporność oraz występowanie efektu lawinowego. Jednokierunkowość oznacza, że dla znanego skrótu jest praktycznie niemożliwe wyliczenie oryginalnych danych wejściowych. Ta cecha chroni przed odtwarzaniem lub ujawnianiem oryginalnej informacji na podstawie samego hasza. Odporność na kolizje zapewnia, że jest niepraktyczne znalezienie dwóch różnych danych wejściowych, które dają ten sam skrót. Dzięki temu można mieć pewność, że dany hasz jednoznacznie identyfikuje konkretny zestaw danych, co jest fundamentalne dla detekcji manipulacji. Innymi słowy dla dwóch różnych wiadomości $m_1 \neq m_2$ powinno być obliczeniowo niemożliwe znalezienie skrótu takiego, że $H(m_1)=H(m_2)$. Efekt lawinowy polega na tym, że nawet minimalna zmiana w danych wejściowych (np. zmiana pojedynczego bitu) powoduje zupełnie inną wartość skrótu, zwykle zmieniając większość bitów w wyniku. Ta właściwość zwiększa zdolność do wykrywania nawet niewielkich modyfikacji danych. Funkcje skrótu, które posiadają wszystkie trzy powyższe cechy, stanowią podstawy wielu protokołów kryptograficznych, systemów weryfikacji integralności danych, podpisów cyfrowych czy mechanizmów uwierzytelniania (Katz, Lindell, 2014). W kontekście zabezpieczania modeli AI szczególnie ważna jest odporność na kolizje, ponieważ umożliwia wykrywanie prób fałszowania lub wstrzykiwania zmanipulowanych danych treningowych (Tabela 1).

Tabela 1. Wykaz użytych algorytmów haszujących

Algorytm	Jak działa w skrócie	Długość hasz'a	Bezpieczeństwo	Główne zastosowanie
MD5	Bardzo szybki, ale dziś łatwo złamać (można znaleźć dwie różne dane dające ten sam hasz).	32 znaki (128 bitów)	Słaby	Sprawdzanie integralności plików (nie do haseł!)
SHA-1	Ulepszony MD5, ale też już przestarzały – można znaleźć kolizje.	40 znaków (160 bitów)	Średni	Stare systemy, podpisy cyfrowe (już niezalecany)

Algorytm	Jak działa w skrócie	Długość hasz'a	Bezpieczeń- stwo	Główne zastosowanie
SHA-256	Mocniejszy i nowszy z rodziny SHA-2; trudny do złamania, popularny.	64 znaki (256 bitów)	Bardzo dobry	Bezpieczeństwo danych, podpisy cyfrowe, certyfikaty
BLAKE2	Szybszy niż SHA-256, a równie bezpieczny; nowoczesny algorytm.	64 znaki (domyślnie)	Bardzo dobry	Nowe aplikacje, kryptografia, blockchain
bcrypt	Inny typ – wolny z premedytacją, co utrudnia łamanie haseł siłowo. Dodatkowo używa soli (losowych danych) przy każdym hasle.	ok. 60 znaków	Najlepszy do haseł	Przechowywanie haseł użytkowników

Źródło: Aumasson, 2024; Aumasson i in., 2017; Rietta, 2016.

Metodologia badań eksperymentalnych

Opis środowiska testowego (sprzęt, oprogramowanie, wersje bibliotek)

Testy przeprowadzono na sprzęcie klasy biurowej, aby możliwie wiernie odzwierciedlić warunki pracy typowego użytkownika końcowego. Do badań wykorzystano trzy komputery przenośne o zróżnicowanej konfiguracji sprzętowej, co umożliwiło analizę wpływu parametrów technicznych na wyniki eksperymentów.

Pierwszy z nich to laptop MSI, wyposażony w procesor AMD Ryzen 5 7535HS, zintegrowany układ graficzny Radeon oraz dedykowaną kartę graficzną NVIDIA GeForce RTX 4060 z 8 GB pamięci VRAM. Urządzenie posiada 16 GB pamięci operacyjnej RAM.

Drugi laptop, marki ACER, wykorzystuje procesor Intel Core i5 jedenastej generacji oraz dedykowaną kartę graficzną NVIDIA GeForce RTX 3050 z 4 GB pamięci VRAM. Wyposażony jest również w 16 GB pamięci RAM, co zapewnia stabilną wydajność w zastosowaniach wielozadaniowych.

Trzeci z opisywanych komputerów to Apple MacBook Air z procesorem Apple M1, zintegrowanym układem graficznym oraz 8 GB zintegrowanej pamięci RAM. Charakteryzuje się wysoką efektywnością energetyczną i optymalizacją pod kątem środowiska macOS.

Programy wykorzystane w procesie eksperymentalnym: Visual Studio Code, PowerShell, PyCharm.

Do realizacji eksperymentów zastosowano dwa języki programowania – Python oraz Rust. Wybór tych języków wynikał z chęci porównania ich wydajności, sposobu implementacji oraz efektywności funkcji skrótu (haszy) w językach wysokiego poziomu o odmiennych paradygmatach programistycznych i charakterystyce działania.

Implementacja skryptu badawczego

W celu przeprowadzenia pomiarów wydajności różnych funkcji skrótu przygotowano dwa niezależne skrypty badawcze – jeden w języku Python, a drugi w Rust. Oba programy realizują tę samą logikę pomiarową, różniąc się jedynie składnią i sposobem zarządzania czasem wykonania. Takie podejście umożliwia porównanie nie tylko samych algorytmów haszujących, lecz również potencjalnych różnic wynikających z implementacji w odmiennych językach programowania.

Generowanie danych wejściowych

W obu programach zastosowano pseudolosowe generowanie ciągów znaków o zadanej długości. Ciągi te tworzone są z zestawu znaków alfanumerycznych (A-Z, a-z, 0-9). Wartość generowanego ciągu nie ma znaczenia dla wyników eksperymentu – istotna jest jedynie jego długość, wpływająca na czas obliczenia funkcji skrótu. Wersja Pythona korzysta z modułu `random`, natomiast wersja w języku Rust wykorzystuje bibliotekę `rand::Rng`.

Zakres badanych algorytmów

Do testów wydajności wybrano pięć popularnych funkcji skrótu.

- Implementacja w języku Python

Skrypt w Pythonie został zbudowany w oparciu o biblioteki: `hashlib`, `bcrypt`, `random`, `string`, `time`, `pandas` oraz `numpy`. Program umożliwia użytkownikowi określenie liczby testowanych ciągów oraz zakresu ich długości. Dla

każdego algorytmu i każdej długości ciągu wykonywana jest wielokrotna seria pomiarów czasu. Czas mierzony jest przy użyciu funkcji `time.perf_counter()`, która oferuje wysoką precyzję pomiaru w sekundach z ułamkami milisekund. Dane z pomiarów są następnie zapisywane do obiektu `DataFrame`, a na ich podstawie obliczane są średnie wartości czasu haszowania dla poszczególnych długości i algorytmów. Wyniki prezentowane są w formie tabelarycznej (`pivot table`) w konsoli, z dokładnością do sześciu miejsc po przecinku.

– Implementacja w języku Rust

Analogiczny skrypt w języku Rust wykorzystuje biblioteki `rand::std`, `md5`, `sha1`, `sha256`, `blake2` oraz `bcrypt`. Pomiar czasu realizowany jest z wykorzystaniem struktury `Instant` z modułu `std::time`, która pozwala na dokładne określenie czasu trwania operacji w sekundach.

Program testuje trzy różne długości wejściowych ciągów znaków (np. 10, 30 i 60 znaków), a dla każdego algorytmu wykonuje kilka powtórzeń w celu uśrednienia wyników. Średni czas obliczeń dla każdej funkcji haszującej obliczany jest jako średnia arytmetyczna z uzyskanych czasów (`as_secs_f64()`), po czym prezentowany w czytelnej formie tabelarycznej w konsoli.

Sposób przeprowadzenia pomiarów

Każdy eksperyment przebiega według następującej sekwencji kroków:

1. Generacja losowego ciągu znaków o określonej długości.
2. Rozpoczęcie pomiaru czasu (`Instant::now()` / `time.perf_counter()`).
3. Obliczenie skrótu za pomocą wybranego algorytmu.
4. Zatrzymanie pomiaru i zapis czasu wykonania.
5. Powtórzenie operacji dla wszystkich algorytmów i długości.

Tak uzyskane czasy dla wszystkich algorytmów są następnie uśredniane, co pozwala zminimalizować wpływ jednorazowych fluktuacji środowiska uruchomieniowego (np. obciążenia procesora). Wyniki operacji przedstawiono na Rysunkach 1-6.

Algorithm	BLAKE2	MD5	SHA-1	SHA-256	bcrypt
String Length					
10	0.00000983	0.00001777	0.00000732	0.00000713	0.45758470
30	0.00000208	0.00000158	0.00000143	0.00000144	0.45690823
60	0.00000202	0.00000174	0.00000157	0.00000153	0.44477743

Rysunek 1. Wyniki pomiarów na komputerze MSI w środowisku Python

Źródło: opracowanie własne.

```
PS C:\Users\zyx\Desktop\pracanaukowa\hashrust> cargo run main.rs
Compiling hash v0.1.0 (C:\Users\zyx\Desktop\pracanaukowa\hashrust)
Finished `dev` profile [unoptimized + debuginfo] target(s) in 3.71s
Running `target\debug\hash.exe main.rs`
```

Length	MD5	SHA1	SHA256	BLAKE2	BCRYPT
10	0.000011	0.000005	0.000013	0.000045	0.625615
30	0.000004	0.000003	0.000009	0.000025	0.624331
60	0.000005	0.000006	0.000012	0.000028	0.621467

Rysunek 2. Wyniki pomiarów na komputerze MSI w środowisku Rust

Źródło: opracowanie własne.

Algorithm	BLAKE2	MD5	SHA-1	SHA-256	bcrypt
String Length					
10	0.00036406	0.00000234	0.00000120	0.00000114	0.24879453
30	0.00000079	0.00000094	0.00000088	0.00000089	0.23504114
60	0.00000080	0.00000103	0.00000092	0.00000095	0.21499794

Rysunek 3. Wyniki pomiarów na komputerze ACER w środowisku Python

Źródło: opracowanie własne.

```
Finished `dev` profile [unoptimized + debuginfo] target(s) in 1.38s
Running `target\debug\hash_benchmark.exe`
```

Length	MD5	SHA1	SHA256	BLAKE2	BCRYPT
10	0.000008	0.000004	0.000012	0.000037	0.587911
30	0.000004	0.000003	0.000010	0.000026	0.583712
60	0.000006	0.000006	0.000011	0.000024	0.597863

Rysunek 4. Wyniki pomiarów na komputerze ACER w środowisku Rust

Źródło: opracowanie własne.

Algorithm	BLAKE2	MD5	SHA-1	SHA-256	bcrypt
String Length					
10	0.00000046	0.00000080	0.00000044	0.00000043	0.23301162
30	0.00000038	0.00000046	0.00000042	0.00000040	0.23308694
60	0.00000038	0.00000057	0.00000042	0.00000041	0.23274149
Process finished with exit code 0					

Rysunek 5. Wyniki pomiarów na komputerze MacBook w środowisku Python

Źródło: opracowanie własne.

Finished	`dev` profile [unoptimized + debuginfo] target(s) in 0.08s				
Running	`/Users/waleria/Desktop/hashrust/target/debug/hash`				
Length	MD5	SHA1	SHA256	BLAKE2	BCRYPT
10	0.000016	0.000006	0.000036	0.000051	1.487426
30	0.000008	0.000006	0.000018	0.000037	1.476239
60	0.000015	0.000013	0.000021	0.000031	1.475577

Rysunek 6. Wyniki pomiarów na komputerze MacBook w środowisku Rust

Źródło: opracowanie własne.

Prezentacja wyników

Wyniki pomiarów wyświetlane są w formie tabelarycznej, gdzie w wierszach znajdują się długości testowanych ciągów, a w kolumnach – czasy wykonania dla poszczególnych funkcji skrótu. Dzięki temu możliwe jest wizualne porównanie wydajności algorytmów. Uzyskane dane w dalszej części pracy zostały wykorzystane do analizy statystycznej i opracowania wykresów zależności czasu haszowania od długości ciągu wejściowego.

Wyniki pomiarów

Zestawienie czasów obliczeń dla różnych algorytmów (Tabele 2-3, Rysunek 7).


Tabela 2. Wyniki pomiarów dla środowiska Python

Długość ciągu	Platforma	Czas wykonania funkcji skrótu				
		MD5	SHA-1	SHA-256	Blake2	bcrypt
10	MSI	0.00001777	0.00000732	0.00000713	0.00000983	0.45758470
	ACER	0.00000234	0.00000120	0.00000114	0.00036406	0.24879453
	MacBook	0.00000080	0.00000044	0.00000043	0.00000046	0.23301162
30	MSI	0.00000158	0.00000143	0.00000144	0.00000208	0.45690823
	ACER	0.00000094	0.00000088	0.00000089	0.00000079	0.23504114
	MacBook	0.00000046	0.00000042	0.00000040	0.00000038	0.23308694
60	MSI	0.00000174	0.00000157	0.00000153	0.00000202	0.44477743
	ACER	0.00000103	0.00000092	0.00000095	0.00000080	0.21499794
	MacBook	0.00000057	0.00000042	0.00000041	0.00000038	0.23274149

Tabela 3. Wyniki pomiarów dla środowiska Rust

Długość ciągu	Platforma	Czas wykonania funkcji skrótu				
		MD5	SHA-1	SHA-256	Blake2	bcrypt
10	MSI	0.000011	0.000005	0.000013	0.000045	0.625615
	ACER	0.000008	0.000004	0.000012	0.000037	0.587911
	MacBook	0.000016	0.000006	0.000036	0.000051	1.487426
30	MSI	0.000004	0.000003	0.000009	0.000025	0.624331
	ACER	0.000004	0.000003	0.00001	0.000026	0.583712
	MacBook	0.000008	0.000006	0.000018	0.000037	1.476239
60	MSI	0.000005	0.000006	0.000012	0.000028	0.621467
	ACER	0.000006	0.000006	0.000011	0.000024	0.597863
	MacBook	0.000015	0.000013	0.000021	0.000031	1.475577

Źródło: opracowanie własne.



Rysunek 7. Porównanie czasu działania algorytmów haszujących wykonywane w środowiskach Python oraz Rust

Źródło: opracowanie własne.

Na podstawie precyzyjnych pomiarów czasu wykonania identycznego zestawu algorytmów haszujących (MD5, SHA-1, SHA-256, BLAKE2, bcrypt) na trzech platformach sprzętowych w dwóch środowiskach programistycznych, uzyskano następujące rezultaty.

Python

- Wydajność dla bcrypt jest stosunkowo stała przy rosnącej długości tekstu (10 → 60 znaków), co wskazuje na znaczący wpływ samej złożoności algorytmu, a nie długości danych.
- Dla większości lekkich algorytmów (MD5, SHA-1, SHA-256, Blake2) MacBook i ACER osiągają niemal identyczne czasy (~0.0000004-0.000002s), natomiast MSI w przypadku krótkich tekstów (10 znaków) wykazuje wyraźnie większe opóźnienia (np. MD5: 0.00001777 s).
- Najwolniejszym algorytmem we wszystkich konfiguracjach jest bcrypt, gdzie najkrótsze czasy uzyskuje MacBook (~0.233 s), a najdłuższe MSI (~0.457 s).

Rust

- Najszybsze wykonania lekkich algorytmów (MD5, SHA-1, SHA-256, Blake2) osiąga ACER i MSI, w granicach ~0.0000004-0.000011s. MacBook jest nieco wolniejszy, szczególnie przy SHA-256 (0.0000036 s dla krótkiego tekstu).
- Algorytm bcrypt pozostaje najbardziej wymagający: najkrótsze czasy uzyskuje ACER (~0.584 s), a najdłuższe MacBook (~1.487s).

Mimo że Rust jest językiem kompilowanym, charakteryzującym się wysoką wydajnością przy ogólnych obliczeniach, w tym konkretnym scenariuszu czas haszów dla krótkich stringów jest relatywnie krótki (rzędu mikrosekund). W takich przypadkach czas wykonywania kodu nie zależy głównie od języka, lecz od:

1. Przełączeń kontekstu i narzutów środowiskowych – inicjalizacja funkcji haszujących, wywołania bibliotek kryptograficznych, zarządzanie pamięcią mogą stanowić większą część czasu niż same obliczenia.
2. Optymalizacji niskopoziomowych w bibliotekach Pythona – np. algorytmy haszujące w Pythonie korzystają z dobrze zoptymalizowanych implementacji C, które działają szybciej niż ręcznie zaimplementowany Rust w tym samym teście.
3. Krótki czas operacji – przy tak mikroskopijnych czasach pojedynczych operacji (mikro- lub nanosekundy) nawet minimalne różnice

w wywołaniu funkcji, zarządzaniu pamięcią czy synchronizacji mogą sprawić, że Rust wydaje się wolniejszy od Pythona, mimo że w dużych i długotrwałych obliczeniach przewaga Rusta byłaby znacząca.

Zależność między szybkością a bezpieczeństwem

1. Szybkie algorytmy (MD5, SHA-1, SHA-256, Blake2):
 - charakteryzują się bardzo krótkim czasem obliczeń (~mikrosekundy dla pojedynczego stringa);
 - z punktu widzenia systemu szyfrowania haseł lub generowania tokenów, ich szybkość jest korzystna dla wydajności, ale jednocześnie ułatwia atak brute-force. Atakujący z odpowiednim sprzętem (GPU lub FPGA) może wykonywać miliony prób na sekundę;
 - dlatego algorytmy te są bezpieczne dla integralności danych, ale nie nadają się do bezpiecznego przechowywania haseł bez dodatkowych mechanizmów spowalniających (salting, key stretching, iteracje).
2. Wolniejsze, algorytmy (bcrypt, scrypt, Argon2):
 - wymagają kilkudziesięciu do kilkuset milisekund na pojedyncze haszowanie, co znacząco ogranicza liczbę prób możliwych do wykonania przez atakującego w jednostce czasu;
 - przykładowo, w przeprowadzonych pomiarach bcrypt wymaga ~0,187 s (MSI, Python) do ~1,48 s (MacBook, Rust) na jedną próbę, co redukuje potencjalną prędkość ataku brute-force o kilka rzędów wielkości w porównaniu z MD5 czy SHA-256;
 - takie algorytmy są projektowane specjalnie pod kątem bezpieczeństwa haseł, gdzie celem jest maksymalne ograniczenie liczby prób w określonym czasie przy zachowaniu akceptowalnej wydajności dla użytkownika.

Wpływ mocy obliczeniowej atakującego

- Liczba prób, jaką atakujący może wykonać w jednostce czasu, rośnie proporcjonalnie do dostępnej mocy obliczeniowej (CPU, GPU, FPGA).

- Dla algorytmów szybkich, wzrost mocy obliczeniowej powoduje niemal liniowy wzrost liczby prób, co znacząco obniża bezpieczeństwo.
- Dla algorytmów spowolnionych, nawet duży wzrost mocy obliczeniowej daje ograniczoną poprawę liczby prób na sekundę, ponieważ projekt algorytmu wprowadza narzut czasowy, który jest trudny do obejścia.

Analiza bezpieczeństwa

Jak wspomniano wcześniej, najważniejszą właściwością kryptograficzną funkcji skrótu jest odporność na kolizje – dla dwóch różnych wiadomości $m_1 \neq m_2$ powinno być obliczeniowo niemożliwe znalezienie takich danych wejściowych, dla których zachodzi równość $H(m_1)=H(m_2)$. Powiązanym z tą właściwością parametrem wpływającym na bezpieczeństwo jest długość skrótu, która determinuje przestrzeń możliwych wyników i tym samym odporność na ataki typu brute-force. Przykładowo, długość skrótu 128 bitów zapewnia 2^{128} możliwych wyników, co jednak w przypadku współczesnych mocy obliczeniowych nie gwarantuje już wystarczającej odporności kryptograficznej.

MD5, opracowany przez R. Rivesta w 1991 r., generuje skróty o długości 128 bitów. Już w 2004 roku wykazano możliwość generowania kolizji w czasie rzeczywistym, co spowodowało jego całkowitą dyskwalifikację jako funkcji kryptograficznej. „Wang przedstawia przepis na znajdowanie kolizji dla dwublokowych wiadomości. Znalezienie kolizji na komputerze klasy PC zajmuje około godziny” (Rodwald, 2013). Dziś MD5 uznawany jest wyłącznie za narzędzie kontrolne (np. do wykrywania błędów transmisji), ale nie do celów bezpieczeństwa.

SHA-1, opracowany przez NSA w 1995 r., generuje skróty 160-bitowe. W 2017 roku zespół z Google i CWI Amsterdam opublikował pierwszą praktyczną kolizję (projekt SHAttered), co ostatecznie potwierdziło niewystarczający poziom bezpieczeństwa SHA-1 w zastosowaniach kryptograficznych. Obecnie funkcja ta jest wycofywana z użycia w certyfikatach SSL/TLS i systemach podpisów cyfrowych.

SHA-256, stanowiący część rodziny SHA-2, jest obecnie jednym z najczęściej stosowanych algorytmów funkcji skrótu w praktyce. Zapewnia długość skrótu 256 bitów i nie posiada znanych praktycznych ataków skutkujących

kolizją. Pomimo kilku teoretycznych analiz redukujących złożoność obliczeniową ataków (Nahiyen, 2024), poziom bezpieczeństwa SHA-256 pozostaje wysoki.

BLAKE2, opracowany w 2013 roku jako następca finalisty konkursu SHA-3 (BLAKE), łączy bardzo wysoki poziom bezpieczeństwa z efektywnością energetyczną i wydajnością implementacyjną. Wykazuje odporność porównywalną do SHA-3, przy czym działa znacznie szybciej w oprogramowaniu. BLAKE2 jest rekomendowany w wielu współczesnych projektach open source i protokołach kryptograficznych.

Bcrypt to funkcja bazująca na szyfrze blokowym Blowfish, zaprojektowana w 1999 r. specjalnie dla bezpiecznego przechowywania haseł. Jej głównym mechanizmem ochronnym jest możliwość konfigurowalnego spowolnienia obliczeń (tzw. *cost factor*), dzięki czemu ataki typu brute-force i słownikowe stają się nieopłacalne obliczeniowo. Bcrypt jest odporna na technologię GPU i ASIC, co czyni ją szczególnie skuteczną w ochronie haseł użytkowników.

Ewolucja funkcji skrótu od MD5 i SHA-1 do współczesnych konstrukcji, takich jak SHA-256 czy BLAKE2, obrazuje rosnące wymagania bezpieczeństwa w kryptografii. W praktyce, preferowanym wyborem są dziś funkcje SHA-256, SHA-3 lub BLAKE2.

Ataki typu *data poisoning* w kontekście AI

Ataki typu *data poisoning* stanowią jedne z najbardziej niebezpiecznych zagrożeń dla modeli sztucznej inteligencji, które opierają się na uczeniu maszynowym. Polegają one na celowym zanieczyszczeniu danych wykorzystywanych podczas trenowania modelu poprzez wprowadzanie do zbiorów treningowych próbek, które zostały zmanipulowane w taki sposób, aby model nauczył się błędnych lub szkodliwych zależności. Dzięki temu po wytrenowaniu model może wykazywać nieoczekiwane i często bardzo trudne do wykrycia błędy wywierające istotny wpływ na jego działanie i bezpieczeństwo.

Manipulacje danymi wejściowymi, mogą przyjmować różnorodne formy. Jednym z przypadków jest wstrzykiwanie złośliwych przykładów do zbioru treningowego, które mimo iż wyglądają na integralne, zawierają ukryte cechy mające na celu wywołanie nieprawidłowej klasyfikacji lub błędów decyzyjnych w modelu. Innym sposobem jest zmiana etykiet przypisanych do danych, tzw.

label flipping, gdzie odpowiedzi w zbiorze treningowym są celowo błędne, co prowadzi do utrwalenia niepoprawnych wzorców w modelu. Ponadto, istnieją subtelne metody manipulacji, które wprowadzają drobne i często niemożliwe do zauważenia przez człowieka zakłócenia.

Wpływ takich zmanipulowanych danych na proces trenowania i końcową jakość modelu jest znaczący. Nawet niewielka liczba skażonych danych może zafałszować całą przestrzeń uczącą, skutkując obniżeniem dokładności oraz ryzykiem powtarzalnych błędów przy określonych warunkach wejściowych. W skrajnych przypadkach model może być w pełni kontrolowany przez atakującego, który wykorzystuje zatrucie danych do uzyskania celowo błędnych wyników, na przykład w systemach bezpieczeństwa, gdzie wprowadzenie fałszywych próbek może pozwolić na obejście mechanizmów kontrolnych.

W obliczu tych zagrożeń funkcje skrótu zyskują na dużym znaczeniu jako podstawowe narzędzie ochrony integralności danych. Dzięki swojej właściwości jednokierunkowości, funkcje te umożliwiają szybkie i pewne wyliczenie unikatowych sygnatur (haszy) dla danych treningowych, które w razie jakiegokolwiek zmiany w zawartości ulegają radykalnej i nieprzewidywalnej zmianie. Odporność na kolizje gwarantuje, że praktycznie niemożliwe jest znalezienie dwóch różnych danych generujących ten sam hasz, co czyni funkcje haszujące skutecznym filtrem wykrywającym nieautoryzowaną ingerencję w dane. Monitoring i porównywanie haszy zbiorów treningowych pozwala na wczesne wykrywanie prób manipulacji i wprowadzenia potencjalnie niebezpiecznych próbek, co znacznie podnosi poziom bezpieczeństwa procesu trenowania modelu.

Powiązanie kolizji haszy z bezpieczeństwem modeli AI

Kolizje haszy są jednym z zagrożeń dla bezpieczeństwa zarówno tradycyjnych systemów kryptograficznych, jak i nowoczesnych modeli sztucznej inteligencji. W kontekście uczenia maszynowego naruszenie odporności funkcji skrótu może prowadzić do sytuacji, w której złośliwy podmiot wprowadza skażone dane do zbiorów treningowych, zachowując jednocześnie ich pozorną autentyczność. W wyniku kolizji – czyli sytuacji, w której dwie różne próbki danych generują ten sam hasz – atakujący jest w stanie ominąć mechanizmy weryfikacji integralności danych, które opierają się na unikalnych wartościach skrótów.

Jednakże, aby w pełni umotywować to zagrożenie w kontekście *data poisoning*, należy podkreślić, że choć dla kryptograficznie bezpiecznych funkcji skrótu kolizje są skrajnie mało prawdopodobne, to realne ryzyko pojawia się właśnie przy stosowaniu algorytmów uznanych za złamane w procesach weryfikacji integralności danych treningowych. Algorytmy MD5 i SHA1 celowo dobrano do weryfikacji integralności plików, ponieważ udowodniono możliwość generowania sprawnej kolizji – atakujący może w czasie rzeczywistym skonstruować złośliwy plik o identycznym skrócie, co czyni ochronę przed atakami *data poisoning* iluzoryczną. Analogicznie, SHA-1 został praktycznie złamany w 2017 roku przez atak SHAttered, który zademonstrował generację kolizji przy złożoności obliczeniowej znacznie poniżej teoretycznego progu bezpieczeństwa. Haszowanie każdego pliku z osobna przy użyciu kryptograficznie złamanych funkcji skrótu nie zapewnia wystarczającej gwarancji integralności w środowiskach narażonych na celową manipulację danymi. W związku z tym „detekcja kolizji haszy” nie jest proponowana jako samodzielny mechanizm wykrywania skażenia, lecz jako ilustracja luki, która powstaje przy niewłaściwym doborze algorytmu. Lukę tę można skutecznie zamknąć poprzez łączenie haszowania z innymi mechanizmami, takimi jak podpisy cyfrowe, drzewa Merkle’a czy systemy provenance.

W efekcie modele uczone na takich danych mogą zostać celowo zdeformowane, co prowadzi do powstania skażonych modeli zachowujących się poprawnie w typowych scenariuszach, ale ujawniających niepożądane zachowania po spełnieniu określonych warunków (Malinowski, 2024).

Znaczenie doboru algorytmu haszującego w tym kontekście bardzo istotne gdyż nie wszystkie funkcje skrótu zapewniają ten sam poziom odporności na ataki kolizyjne i tzw. ataki drugiego obrazu (*second preimage attacks*). Starsze algorytmy, takie jak MD5 czy SHA-1, zostały uznane za niebezpieczne, ponieważ możliwe jest dla nich generowanie celowych kolizji w rozsądnym czasie obliczeniowym. Użycie takich algorytmów w procesie walidacji zbiorów danych lub podpisów kryptograficznych modeli AI może skutkować umożliwieniem niezauważonego wprowadzenia zmodyfikowanych próbek lub całych klas danych o identycznych wartościach haszy. W środowisku, gdzie modele sztucznej inteligencji opierają się na integracji ogromnych zbiorów danych pochodzących z wielu źródeł, istotna jest więc nie tylko szybkość algorytmu ale też fakt, że zastosowanie niewłaściwego algorytmu haszującego może

prowadzić do skażenia całego procesu uczenia. Algorytmy takie jak SHA-256, czy Blake2 oferują znacznie wyższą odporność na kolizje dzięki większej przestrzeni mieszania i udoskonalonej strukturze funkcji kompresującej. Wybór funkcji skrótu powinien być więc uzależniony od charakteru danych, wymaganego poziomu bezpieczeństwa i ryzyka kryptoanalizy różnicowej (Rodwald 2013). W projektowaniu bezpiecznych systemów AI odpornych na złośliwe manipulacje w warstwie danych dobór takiego algorytmu jest istotny.

Wnioski

Badane algorytmy haszujące wykazują różne właściwości w kontekście zabezpieczania modeli AI przed atakami typu *data poisoning*. Algorytmy takie jak MD5 i SHA-1 są obecnie niewystarczająco bezpieczne ze względu na możliwość generowania kolizji, co czyni je nieodpowiednimi do ochrony integralności danych treningowych. Z kolei SHA-256 i BLAKE2 oferują solidną odporność na kolizje, przez co są rekomendowane do zapewnienia integralności danych w procesie trenowania modeli. Algorytmy takie jak bcrypt, choć mają większe czasy obliczeń, są bardzo skuteczne w ochronie haseł dzięki mechanizmom spowalniającym ataki *brute-force*, lecz ich zastosowanie w klasycznym zabezpieczaniu modeli AI jest ograniczone.

Projektanci systemów uczenia maszynowego powinni wybierać algorytmy haszujące o wysokiej odporności na kolizje (np. SHA-256, BLAKE2) do monitorowania integralności danych treningowych oraz parametrów modeli. Przy przechowywaniu haseł i danych wrażliwych rekomenduje się stosowanie algorytmów adaptacyjnych, takich jak bcrypt, aby minimalizować ryzyko złamania haseł. Należy również uwzględniać wydajność oraz kontekst wdrożenia – np. w środowiskach o ograniczonych zasobach może preferować szybsze funkcje.

Wskazane jest pogłębienie integracji technik haszowania z nowoczesnymi mechanizmami uczenia federacyjnego, co mogłoby zapewnić lepszą ochronę integralności rozproszonych modeli i danych bez konieczności centralnego udostępniania danych. Kolejnym kierunkiem jest rozwijanie algorytmów detekcji kolizji haszy dostosowanych do specyfiki zagrożeń w AI, a także badania nad nowymi konstrukcjami funkcji skrótu odpornych na ataki specyficzne dla uczenia maszynowego, takie jak ataki *adversarialne* i *data poisoning*.

Równocześnie powinno się analizować kompromisy między bezpieczeństwem a wydajnością, aby umożliwić szerokie wdrożenie efektywnych technik w systemach produkcyjnych.

Literatura

1. Albertini, A., Stevens, M. (b.d.). *Collisions: Hash collisions and exploitations*. GitHub repository. Pobrane z: <https://github.com/corkami/collisions> (dostęp: 16.03.2026).
2. Al-Odat, Z., Khan, S. (2019). The Sponge Structure Modulation Application to overcome the security breaches for the MD5 and SHA-1 hash functions. W: *IEEE 43rd Annual Computer Software and Applications Conference (COMPSAC), Milwaukee, WI, USA* (s. 811-816). IEEE. <https://doi.org/10.1109/COMPSAC.2019.00119>
3. Aumasson, J.-P. (2024). *Serious cryptography: a practical introduction to modern encryption*. 2nd edition. No Starch Press.
4. Aumasson, J.-P., Neves, S., Wilcox-O'Hearn, Z., Winnerlein, C. (2017). *BLAKE2 – fast secure hashing*. Pobrane z: <https://www.blake2.net> (dostęp: 12.12.2025).
5. Biggio, B., Roli, F. (2018). Wild patterns: ten years after the rise of adversarial machine learning. *Pattern Recognition*, 84, 317-331. <https://doi.org/10.1016/j.patcog.2018.07.023>
6. Cao, D., Yang, B. (2010). Design and implementation for MD5-based data integrity checking system. W: *2nd IEEE International Conference on Information Management and Engineering, Chengdu, China, 2010* (s. 608-611). IEEE. <https://doi.org/10.1109/ICIME.2010.5477912>
7. Dash, S. P., Khandeparkar, K. V., Gajjar, G. (2025). A GAN-based data integrity attack on wide-area damping control systems in the smart grid. W: *5th International Conference on AI-ML-Systems (AIMLSystems), Bangalore, India* (s. 56-60). IEEE. <https://doi.org/10.1109/AIMLSystems67835.2025.11330765>
8. Eastlake, D., Jones, P. (2001). US secure hash algorithm 1 (SHA1). *RFC 3174*. <https://doi.org/10.17487/RFC3174>
9. Gu, T., Dolan-Gavitt, B., Garg, S. (2017). BadNets: Identifying vulnerabilities in the machine learning model supply chain. *arXiv*, 1708.06733. <https://doi.org/10.48550/arXiv.1708.06733>

10. Katz, J., Lindell, Y. (2014). *Introduction to modern cryptography* (2nd ed.). Chapman and Hall/CRC. <https://doi.org/10.1201/b17668>
11. Klabnik, S., Nichols, C. (2021). *The Rust Programming Language*, 2nd edition. No Starch Press.
12. Kurakin, A., Goodfellow, I., Bengio, S. (2017). Adversarial examples in the physical world. *arXiv*, 1607.02533. <https://doi.org/10.1201/9781351251389-8>
13. Malinowski, M. (2024). *Adwersarialne ataki na sztuczną inteligencję*. Pobrane z: <https://www.drmalinowski.edu.pl/posts/2824-adwersarialne-ataki-na-sztuczna-inteligencje> (dostęp: 12.12.2025).
14. Nahiyani, A., Nejati, S., Bright, C. (2024). SHA-256 Collision Attack with Programmatic SAT. *arXiv*, 2406.20072v1. <https://doi.org/10.48550/arXiv.2406.20072>
15. Rietta, F. (2016). *What is the difference between bcrypt and SHA256?*. Pobrane z: <https://rietta.com/blog/bcrypt-not-sha-for-passwords/> (dostęp: 12.12.2025).
16. Rivest, R. (1992). The MD5 message-digest algorithm. *RFC 1321*. <https://doi.org/10.17487/RFC1321>
17. Rodwald, P. (2013). Kryptograficzne funkcje skrótu. *Zeszyty Naukowe Akademii Marynarki Wojennej*, 193.
18. Stallings, W. (2017). *Cryptography and Network Security: Principles and Practice*. Pearson.
19. Turner, S., Chen, L. (2011). Updated security considerations for the MD5 message-digest and the HMAC-MD5 algorithms. *RFC 6151*. <https://doi.org/10.17487/RFC6151>
20. Younis, R., AlKasassbeh, M. (2025). Evaluating deep learning for detecting data integrity attacks in energy smart grids. W: *International Conference on New Trends in Computing Sciences (ICTCS)*, Amman, Jordan (s. 368-372). IEEE. <https://doi.org/10.1109/ICTCS65341.2025.10989460>

OD PROJEKTU DO SZWU. ZASTOSOWANIE AI W KRAWIECTWIE

FROM DESIGN TO STITCH: THE USE OF AI IN TAILORING

Streszczenie

Praca dotyczy wykorzystania AI w pracowni krawieckiej. Celem opracowania było zbadanie poziomu wiedzy, postaw oraz barier wdrożenia sztucznej inteligencji wśród grupy 57 właścicieli małych i średnich pracowni krawieckich mających siedzibę na terenie województwa dolnośląskiego i lubuskiego. Badanie miało charakter pilotażowy i eksploracyjny, a dobór próby był celowy. Ważną kwestią w prowadzonych badaniach było zidentyfikowanie barier, korzyści oraz obszarów zastosowania AI w kontekście efektywności i konkurencyjności w krawiectwie. Autorka zastosowała metodę krytycznej analizy literatury przedmiotu i badania ankietowe przeprowadzone w III kwartale 2025 roku. W efekcie zdefiniowała aktualny stan branży, zmiany techniczne w krawiectwie i pracy krawca oraz potencjalne obszary zastosowania technologii AI w krawiectwie. Badane pracownice krawieckie są gotowe na wdrożenie sztucznej inteligencji – brakuje im wiedzy technologicznej i pierwszych doświadczeń. Najlepszą strategią są według badanych szkolenia połączone z prostymi wdrożeniami, które pokażą realne korzyści dla efektywności i konkurencyjności pracowni. Wyniki, chociaż mają wstępny charakter i wymagają potwierdzenia w szerszych badaniach, wskazują na duży potencjał łączenia tradycyjnego rzemiosła z technologiami cyfrowymi.

Słowa kluczowe: krawiec, krawiectwo, AI, technologia, digitalizacja

¹ <https://orcid.org/0000-0002-2826-6244>, e-mail: jnowicka@ans.edu.pl

Nowicka, J. (2026). Od projektu do szwu. Zastosowanie AI w krawiectwie. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 181-207). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_10

Abstract

The study focuses on the use of AI in tailoring workshops. The aim of the study was to examine the level of knowledge, attitudes and barriers to the implementation of artificial intelligence among 57 owners of small and medium-sized tailoring workshops based in the Lower Silesia and Lubusz provinces. The study was pilot and exploratory in nature, and the sample was selected purposefully. A key focus of the research was to identify barriers, benefits and areas of application for AI in the context of efficiency and competitiveness in tailoring. The author employed a method of critical literature review and a questionnaire survey conducted in the third quarter of 2025. As a result, she defined the current state of the industry, technical changes in tailoring and the work of tailors, and potential areas of application for AI technology in tailoring. The tailoring workshops surveyed are ready to implement artificial intelligence – they lack technological knowledge and initial experience. According to the respondents, the best strategy involves training combined with simple implementations that demonstrate tangible benefits for the workshop's efficiency and competitiveness. Although preliminary and requiring confirmation through broader research, the results point to significant potential in combining traditional craftsmanship with digital technologies.

Keywords: tailor, tailoring, AI, technology, digitalisation

Wstęp

Rozwój i kryzysy branży krawieckiej w Polsce stanowią wyraźne odbicie szerszych procesów społeczno-gospodarczych, obejmujących okres powojennej rekonstrukcji, przez transformację systemową przełomu lat 80. i 90. XX wieku oraz aktualne wyzwania wynikające z globalizacji rynku mody, dominacji *fast fashion*, imperatywem zrównoważonego rozwoju i zasad gospodarki obiegu zamkniętego. Ubrania zawsze były i pozostaną podstawową potrzebą człowieka, pełniąc funkcję społeczną (tożsamość, status) i gospodarczą (źródło zatrudnienia, dochodu). Globalny rynek odzieżowy w 2024 roku według danych Fortune Business Insights był wart 1,8 bln USD a 2,3 bln USD w 2023 roku, polski sektor zaś 53-66 mld zł w latach 2022-2024 (Fortune Business Insights, 2025).

Chociaż zawód krawca należy do klasycznych profesji rzemieślniczo-usługowych, ewaluował od tradycyjnych ról mistrza cechu krawieckiego, szwacza, wykrawacza, a dziś do operatora sztucznej inteligencji (nadzorującego narzędzia AI w projektowaniu, wirtualnych przymiarkach, optymalizacji

procesu szycia i sprzedaży ubrań)². Starzenie się kadry krawieckiej, braku następców ze specjalistycznymi kompetencjami zawodowymi, niskim prestiżem zawodu, emigracja wykwalifikowanych pracowników oraz dominacja *fast fashion* sprawiają, że sztuczna inteligencja może stanowić kluczową szansę na wzrost konkurencyjności branży krawieckiej (PARP, 2023).

Zmiany technologiczne dotyczą nie tylko codziennej pracy krawca, ale także przebiegu całego procesu produkcji co potwierdza wiele raportów branżowych takich jak McKinsey. Branża jest zgodna, że AI przekracza cele prywatne, a w produkcji dodaje wartość m.in. wspiera szybkie i sprawne procesy, redukuje koszty i ma potencjał aby wygenerować zyski branży powyżej 275 mld USD, przy udziale AI w rynku globalnym mody 2 mld USD w 2024 roku, zakładany jest wzrost jej udziału do poziomu 40-60 mld do 2034 roku według Straits Research (Warade, 2025). Parlament Europejski w 2020 roku wskazał, że sztuczna inteligencja to technologia, która może pomóc europejskim producentom zwiększyć wydajność i sprowadzić fabryki z powrotem do Europy, dzięki wykorzystaniu robotów w produkcji, optymalizacji ścieżek sprzedaży lub przewidywaniu na czas potrzeby serwisu maszyn i awarii w inteligentnych fabrykach. Dodatkowo aż „61% Europejczyków przychylnie patrzy na sztuczną inteligencję i roboty, ale 88% twierdzi, że technologie te wymagają ostrożnego zarządzania (Parlament Europejski, 2020).

Celem badań jest określenie możliwości wykorzystania technologii sztucznej inteligencji, świadomości i gotowości wdrożeniowej małych i średnich pracowni krawieckich w Polsce, a także zidentyfikowanie barier, korzyści oraz obszarów zastosowania AI w kontekście efektywności i konkurencyjności w krawiectwie.

W trakcie badania postawiono pięć hipotez badawczych:

- H1: większość właścicieli małych pracowni krawieckich ma niski poziom wiedzy o sztucznej inteligencji;
- H2: im większa skala działalności, tym większe prawdopodobieństwo wykorzystania narzędzi AI;

² Sztuczna inteligencja (ang. *artificial intelligence* – AI) to zdolność maszyn do wykazywania ludzkich umiejętności, takich jak rozumowanie, uczenie się, planowanie i kreatywność (Parlament Europejski, 2020).

- H3: główne bariery wdrożenia AI to brak wiedzy technicznej i wysokie koszty inwestycji;
- H4: stosowanie AI w projektowaniu ubrań zwiększa efektywność i konkurencyjność pracowni;
- H5: krawiectwo łącząc tradycyjne rzemiosło z cyfrowymi narzędziami ma większy potencjał rozwoju w przyszłości.

W efekcie zastosowania analizy literatury i badań ankietowych autorka zdefiniowała współczesne krawiectwo i kierunki rozwoju, rolę i znaczenie technologii w tym sztucznej inteligencji w procesie tworzenia ubrań a w części empirycznej zaprezentowała wyniki badań pilotażowych, ankietowych w III kwartale 2025 roku wśród 57 zakładów krawieckich mających siedzibę na terenie województwa dolnośląskiego i lubuskiego.

Krawiectwo – charakterystyka branży

Krawiectwo jest definiowane jako dziedzina rzemiosła zajmująca się się projektowaniem, krojeniem z szyciem, przeróbkami i naprawą odzieży oraz bielizny z tkanin i dzianin (Słownik języka polskiego PWN, b.d.). W Polsce działalność ta ma charakter zarówno produkcyjny, jak i usługowy. Zgodnie z Polską Klasyfikacją Działalności (PKD 2007) krawiectwo jest klasyfikowane przede wszystkim w sekcji C – przetwórstwo przemysłowe (14.19.Z – produkcja odzieży i dodatków do odzieży (obejmuje szycie odzieży na miarę, produkcję ubrań z tkanin w tym na zamówienie) oraz podklasie 95.29.Z – naprawa pozostałych artykułów użytku osobistego i domowego (przeróbki, naprawy odzieży) (Rozporządzenie Rady Ministrów, 2007).

Zawód krawcy ma długą historię, sięgającą starożytności, jednak jako wyodrębniona specjalizacja rzemieślnicza ukształtował się w Europie w XII-XIII wieku. W Polsce pierwsze wzmianki o cechu krawców pochodzą z Warszawy z 1282 r. Już wówczas cech dzielił się na krawców płóciennych (specjalizujących się w męskiej odzieży) i jedwabnych (specjalizujących się w odzieży damskiej) (Brożyna, Kossakowska-Jarosz, 2016, s. 7-12) Początkowo zawód krawcy był domeną mężczyzn, podczas gdy kobiety szyły głównie nieformalnie, poza strukturami cechowymi. Od XIII do XVIII wieku krawiectwo było prestiżowym zawodem – krawcy ręcznie szyli, wykonując ekskluzywne zamówienia, dla dworów królewskich i arystokracji. Przełom nastąpił w XIX wieku

wraz z pojawieniem się pierwszych maszyn do szycia. Tradycyjne, ręczne praktyki rzemieślnicze zostały stopniowo uzupełniane, a następnie w dużej mierze zastąpione przez procesy przemysłowe.

W XX wieku rozwój masowej produkcji odzieży zmienił znacząco charakter zawodu. Obok krawców, którzy nadal kompleksowo byli odpowiedzialni za całość procesu powstawania ubrania – wyłoniły się wyspecjalizowane zawody takie jak: szwaczki, krojczy, wykonujący powtarzalne, wąsko wyspecjalizowane czynności w warunkach produkcji wielkoseryjnej i masowej. Wokół zawodu krawca wykształcił się zespół wyspecjalizowanych profesji, takich jak szwaczka (realizuje fragment procesu produkcji, wykonuje czynność szycia, ale nie projektuje), bieliźniarz (zajmujących się szyciem bielizny osobistej), gorseciarka (specjalizujących się w wykonywaniu konstrukcji modelujących sylwetkę), kapelusznik (projektowanie i wykonywanie nakryć głowy), ale także krojczy, konstruktor odzieży (Ministerstwo Edukacji Narodowej, b.d.a, s. 15) Krawiectwo występuje w różnych formach – miarowe, przemysłowe, artystyczne jak i usługowe – różniąc się np. poziomem indywidualizacji, podejściem do klienta, stopniem zaawansowania stosowanych technologii (Rysunek 1).



Rysunek 1. Typologia krawiectwa

Źródło: opracowanie własne.

Współczesna pracownia krawiecka to przestrzeń łącząca kreatywność, sztukę rzemiosła artystycznego i nowoczesne technologie produkcji odzieży. Działalność krawiecka najczęściej realizowana jest w jednej z trzech podstawowych form organizacyjno-prawnych:

- pracownie krawieckie i zakłady usługowe (oferujące szycie na miarę, przeróbki, dopasowania, ich siłą jest indywidualne podejście i relacja

- z klientem, często prowadzone przez osoby z wieloletnim doświadczeniem rzemieślniczym),
- szwalnie przemysłowe (średnie i duże przedsiębiorstwa produkujące odzież w seriach pod własną marką lub pod obcą w ramach kontraktów, wykorzystują linie produkcyjne, najnowsze technologie, aby równoważyć ceny z jakością, najczęściej zlokalizowane w regionach o tradycjach włókienniczych takich jak łódzkie, mazowieckie, śląskie, małopolskie),
 - domy mody i marki autorskie (mniej rozpoznawalne firmy z sektora premium, *slow fashion*, mające własny, unikatowy design, oparte na materiałach najwyższej jakości, łączą rzemiosło z marketingiem i technologią, kreują marki np. własne projektantów, regionalne).

Krawiectwo to działalność usługowa, jak i quasi-produkcyjna. W wymiarze usługowym obejmuje szycie odzieży na miarę, wykonywanie poprawek oraz naprawę odzieży. Prace te realizowane są na indywidualne zlecenie klienta i odpowiadają na jego specyficzne potrzeby dotyczące kroju, sylwetki, stylu oraz ewentualnych modyfikacji. Proces ten wymaga ścisłej współpracy z klientem na poszczególnych etapach realizacji, a nie wyłącznie dostarczenie gotowego produktu końcowego. Jako działalność produkcyjna, w skali jednostkowej, seryjnej lub masowej, krawiectwo obejmuje proces wytwarzania przygotowanych kolejnych elementów ubrania przez specjalistów związaną – takich jak technolog krojczy czy szwaczki – przy użyciu materiałów takich jak tkaniny, dzianiny, nici oraz dodatki krawieckie. Efektem końcowym jest fizycznym produkt w postaci gotowej odzieży.

Krawiectwo, jak wcześniej wspomniano figuruje na liście zawodów rzemieślniczych pod numerem 753105 (Wielkopolska Izba Rzemieślnicza, b.d.) i zgodnie z definicją zawartą w art.2 ustawy o rzemiośle z dnia 22 marca 1989 r. (Dz.U. z 1989 r. Nr 17, poz. 92) rzemiosła oznacza „zawodowe wykonywanie działalności gospodarczej przez osobę fizyczną lub spółkę cywilną osoby fizycznych, z wykorzystaniem jej pracy własnej i kwalifikacji zawodowych” (Ustawa o rzemiośle, 1989). Zawód krawca opiera się na umiejętnościach manualnych, wiedzy praktycznej oraz wieloletnim doświadczeniu. Łączy aspekty techniczne z estetycznymi, a kwalifikacje zawodowe mogą być potwierdzone świadectwem czeladniczym lub dyplomem mistrzowskim.

Na współczesny kształt krawiectwa istotny wpływ wywierają dwa dominujące trendy w branży mody: *fast fashion* i *slow fashion*. Podczas gdy *fast fashion* to odmiana masowej produkcji odzieży, gdzie model biznesowy skoncentrowany na szybkim nie tylko wytwarzaniu ale także dużej rotacji tanich ubrań, aby sprostać aktualnym trendom modowym. *Slow fashion* podkreśla wartość i trwałość, jakość i rzemieślnicze wykonawstwo. Łączy się z modą vintage, ale także z naprawami, przeróbkami i ponownym użyciu wyprodukowanych wcześniej ubrań. *Fast fashion* jak zauważają Cantobelli i in. w badaniach z 2022 roku, oznacza „presję czasu i kosztów”, zamiast trwałości ważny jest trend, moda i krótki czas użytkowania. Podczas gdy „*slow fashion* to powrót do sztuki krawieckiej”. To trend, który podkreśla znaczenie lokalnych, regionalnych materiałów, dodatków, połączenie ubrania z regionem, lokalnymi dostawcami i tradycją (Centobelli i in., 2022). Ubrania są trwałe, wykonane starannie, ręcznie, wpisujące się w równoważone podejście do produkcji i użytkowania ubrań. Jak wskazuje S. Aishwariya, „*slow fashion* nie jest sezonowy. Nie działa jak trend. Wymaga czasu na przygotowanie i produkcję oraz ma określony cel. To holistyczne podejście uwzględnia cały cykl życia produktu” (Aishwariya, 2019).

Zgodnie z danymi portalu Mapa karier, w 2022 roku zawód krawcy w Polsce wykonywało ponad 42 tysiące osób, z czego 66% stanowiły kobiety (Mapa Karier, 2022). Według raportu Państwowej Agencji Rozwoju Przedsiębiorczości (PARP), „*Moda nadal modna*” z 2023 roku, w 2022 roku polska branża mody i innowacyjnych tekstyliów liczyła ponad 36 tysięcy podmiotów gospodarczych i wypracowała przychody przekraczające 53 mld złotych, przy czym największy segment rynku stanowiła moda damska (PARP, 2023). W 2024 roku, jak wynika z analizy Centrum Analiz PKO BP, przychody producentów odzieży (PKD 14) zatrudniających powyżej 9 osób spadły o 2% w porównaniu z poprzednim rokiem, osiągając poziom 5,9 mld zł. Największy udział w przychodach odnotowano w segmencie odzieży roboczej oraz pozostałej odzieży wierzchniej (PKO BP, 2025).

Polski rynek odzieżowo-tekstylny, choć zajmuje trzecie miejsce w Europie pod względem liczby przedsiębiorstw, w 2024 roku osiągnął wartość 66,9 mld zł, z czego 10 mld zł pochodziło z produkcji krajowej. W branży zatrudnionych jest szacunkowo 120-150 tys. pracowników (Newseria, 2025). Wśród mocnych stron polskiej branży odzieżowej wymieniana jest m.in. specjalizacja niszowa (produkcja odzieży roboczej, marek premium, bielizny), rosnące znaczenie odzieży

produkowanej lokalnie, wykwalifikowana kadra i elastyczność przedsiębiorstw. Branża boryka się z silną konkurencją ze strony tanich producentów azjatyckich, rosnącymi kosztami pracy oraz spadkiem tradycyjnych pracowni krawieckich. Jednocześnie widoczny jest rosnący potencjał łączenia tradycyjnego rzemiosła z nowoczesnymi technologiami, w tym sztuczną inteligencją, co może stanowić kluczowy kierunek rozwoju sektora w najbliższych latach (PARP, 2023).

Krawiectwo stanowi integralną część sektora mody i współpracuje z branżą innowacyjnych tekstyliów. Warto więc, wskazując kierunki rozwoju i przyszłość krawiectwa, przywołać głos ekspertów zajmujących się zagadnieniami związanymi z sektorem mody i innowacyjnych tekstyliów, którzy spośród wielu obserwowanych trendów postrzeganych jako możliwości rozwoju dla sektora wymieniają:

- rozwój i zastosowanie tekstyliów i materiałów inteligentnych (pasywnych, aktywnych lub superaktywnych mających zastosowanie w obronności, budownictwie, kosmetologii, sporcie czy przemyśle samochodowy,
- rozwój elektroniki – tekstyliów zintegrowanych z układami elektronicznymi, tzw. elektronika noszona,
- rozwój rynku wyrobów ECO, tj. wyrobów ekologicznych produkowanych z materiałów naturalnych lub przetworzonych,
- zastępowanie tradycyjnych surowców włóknotwórczych surowcami ze źródeł odnawialnych i biodegradowalnych (PARP, 2020).

W 2022 roku, we wspomnianym już badaniu PARP „Moda nadal modna”, blisko 30% pracodawców zadeklarowało w perspektywie najbliższych trzech lat wdrożenie i rozwój rozwiązań cyfrowych pozwalających zmierzyć zdalnie, ale także spersonalizować produkt przed jego produkcją (PARP, 2023).

Podsumowując, współczesne krawiectwo znajduje się zatem na skrzyżowaniu tradycji i nowoczesności. W obliczu dynamicznych zmian technologicznych, globalizacji rynku oraz rosnącej presji konkurencyjnej, zawód ten przechodzi głęboką transformację. Przyszłość branży nie zależy już wyłącznie w masowej produkcji ani w czystym tradycyjnym rzemiośle, lecz w świadomym łączeniu wielowiekowego doświadczenia krawieckiego z rozwiązaniami cyfrowymi, w tym sztuczną inteligencją.

AI w krawiectwie – zmiany technologiczne zawodu i procesu

Technologia zawsze sprzyjała pracy krawca – igły, maszyny do szycia, przyrządy do krojenia czyniły tą pracę łatwiejszą i wygodniejszą a jego umiejętności, wiedza i gust miały wyraz w tworzonych strojach.

Krawiectwo jest zawodem wrażliwym na zmiany społeczne, gospodarcze i technologiczne. Na przestrzeni wieków ewoluowało od tradycyjnego rzemiosła służącego lokalnym potrzebom i cechowego modelu organizacji poprzez masową produkcję przemysłową okresu industrializacji aż po krawiectwo wspomagane cyfrowo. Tabela 1 prezentuje najważniejsze punkty zwrotne w branży krawieckiej od XIX wieku do współczesności.

Tabela 1. Zmiany techniczne, społeczne i gospodarcze mające wpływ na krawiectwo i praca krawca od XIX wieku

Zmiany	Charakterystyka
Maszyna do szycia i rewolucja przemysłowa (XIX wiek), maszyny do szycia Isaac Singer w 1846 roku	<ul style="list-style-type: none"> • Przejście do szycia ręcznego do mechanicznego • Wzrost wydajności i zmniejszeni obciążenia fizycznego • Krawiec, który dotąd szył ręcznie, stał się operatorem maszyny do szycia
Standaryzacja rozmiarów ok. 1880 roku	<ul style="list-style-type: none"> • Rozwój antropometrii (pomiaru ciała) powstanie tabeli rozmiarów • Rozwój produkcji seryjnej • Podział pracy w procesie produkcji odzieży pomiędzy stanowiskami takimi jak: krojczy, szwaczka itp.
Elektryfikacja maszyn ok. 1900 roku	<ul style="list-style-type: none"> • Przejście z napędu nożnego na napęd elektryczny • Rozwój produkcji wielkoseryjnej i masowej – krawiectwo przemysłowe
Systemy CAM automatyzacja krojenia, lata 1967-1980	<ul style="list-style-type: none"> • Komputerowo sterowane systemy krojenia • Redukcja strat materiałowych i optymalizacja zużycia materiału
Systemy CAD cyfrowe projektowanie kroju, lata 1980-1990	<ul style="list-style-type: none"> • Cyfrowe konstruowanie form • Zawód „konstruktor odzieży” • Skrócenie cyklu projektowego • Krawiectwo cyfrowe
Globalizacja produkcji odzieży i <i>fast fashion</i> , lata 1990-2020	<ul style="list-style-type: none"> • Ekstremalne skrócenie cyklu kolekcji • Dominacja taniej i masowej odzieży
Projektowanie 3D i wirtualne prototypy	<ul style="list-style-type: none"> • Rozwój oprogramowania 3D • Ograniczenie fizycznych prototypów
AI – powrót do personalizacji krawiectwa	<ul style="list-style-type: none"> • AI w analizie sylwetki i dopasowania • Inteligentne tkaniny • <i>Slow fashion</i>

Źródło: opracowanie własne na podstawie: Brożyna, Kossakowska-Jarosz, 2016; Soly, 2008; Nowakowski, 2025; Ministerstwo Edukacji Narodowej, b.d.a.

Technologia wspiera pracę krawca nie tylko zwiększając możliwości produkcyjne, ergonomię pracy, ale także jakość wykonywanych wyrobów. Od prostych narzędzi manualnych ewoluowała do złożonych rozwiązań technicznych. Dziś obejmuje nie tylko klasyczne igły, nożyce i maszyny do szycia, lecz także nowoczesne technologie cyfrowe, takie jak CAD, skanery 3D oraz narzędzia oparte na generatywnej sztucznej inteligencji. Tabela 2 prezentuje przykłady maszyn, przyrządów i narzędzi, które współcześnie wspomagają pracę krawca.

Tabela 2. Technologia, narzędzia i przybory krawieckie

Narzędzia, technologia	Charakterystyka	Udział technologii w procesie tworzenia odzieży
Narzędzia ręczne	<ul style="list-style-type: none"> Nożyczki, miara krawiecka, igły, szpilki, liniały krawieckie, kredy krawieckie, akcesoria krawieckie 	Wykonywanie manualnych operacji takich jak mierzenie, cięcie, szycie
Urządzenia prasownicze	<ul style="list-style-type: none"> Żelazko, prasy – elektroniczne urządzenia do prasowania parą lub na sucho Manekiny prasownicze – formy do prasowania na kształt ciała Agregaty prasownicze – stała dostawa pary dla dużych ilości 	Urządzenia do wygładzania i formowania odzieży
Urządzenia do montażu wyrobów odzieżowych	<ul style="list-style-type: none"> Maszyna overlock, maszyna do obszywania krawędzi, zapobiega strzępieniu materiału, Dziurkarka guzikarka – przyspiesza wykańczanie odzieży, jednolite dziurki na guziki Podszywarka – ukrywa szwy i poprawia estetykę wykończenia odzieży Randerka – maszyna do elastycznych szwów Stębnówka – maszyna do prostych szwów Pikówka – maszyna do pikowania, np. w kurtkach Zgrzewarka- łączy materiały syntetyczne, np. w odzieży wodoodpornej 	Do automatyzacji szycia
Urządzenia do projektowania i modelowania form odzieży	<ul style="list-style-type: none"> Skaner odzieżowy – urządzenie do skanowania ciała lub odzieży w 3D Stoły i przybory kreślarskie – do ręcznego rysowania wzorów Program CAD do konstruowania form odzieży – pomaga w precyzyjnym rysowaniu szablonów i symulacji dopasowania Manekiny krawieckie formy ciała do przymiarek 	Do tworzenia wzorów

Narzędzia, technologia	Charakterystyka	Udział technologii w procesie tworzenia odzieży
Krojenie i rozkrój	<ul style="list-style-type: none"> Lina pachworku, quilting do cięcia do skosie i na okrągło Odkrywacz automatyczny – maszyna do automatycznego cięcia Klejarka – urządzenie do klejenia warstw Stół do rozkroju, narzędzia i przyrządy do rozkroju 	Do cięcia i łączenia materiałów
Prasowanie	<ul style="list-style-type: none"> Stoły prasownicze, żelazko parowe, przybory do prasowania, wytwornice pary 	Urządzenia do wygładzania i formowania odzieży

Źródło: opracowanie własne na podstawie: Ministerstwo Edukacji Narodowej, b.d.b; ZPE, b.d.

W procesie modernizacji krawiectwa urządzenia i rozwiązania techniczne przedstawione w Tabeli 3 mogą być w coraz większym stopniu automatyzowane, zrobotyzowane oraz zintegrowane ze sztuczną inteligencją. Tabela sygnalizuje kluczowe obszary pracy krawieckiej oraz stopniowe wdrażanie zaawansowanych rozwiązań technicznych i organizacyjnych. Obecnie, w branży krawieckiej funkcjonuje model hybrydowy, w ramach którego krawiec współpracuje z nowoczesnymi technologiami takimi jak automaty, roboty i narzędzia oparte na sztucznej inteligencji.

Tabela 3. Transformacja zawodu krawca – praca ręczna versus technologie

Obszar	Praca ręczna	Automatyzacja i robotyzacja	Sztuczna inteligencja
Pomiar i dopasowanie	Indywidualne pomiary, przymiarki	Skanery ciała 3D	Analiza sylwetki, rekomendacja fasonów
Projektowanie	Szkic, drapowanie	CAD rysunek cyfrowy	Generatywny design, analiza trendów
Szycie	Detale	Roboty szyczące	Adaptacyjne sterowanie maszyną
Kontrola jakości	Ocena wzrokowa	Czujniki, kamery	Wykrywanie defektów
Logistyka i sprzedaż	Ręczne zarządzanie	Automaty magazynowe	Predykcja popytu, personalizacja oferty

Źródło: opracowanie własne.

Tradycyjne manekiny, stoły kreślarskie i oprogramowanie CAD są uzupełniane przez AI, która generuje wirtualne prototypy, symuluje tkaniny co skraca

cykl produkcji – redukuje ilość fizycznych poprawek, a także czas od pomysłu do wyprodukowania. AI to technologia, która w przeciwieństwie do dotychczasowych rozwiązań takich jak praca ręczna, automatyzacja i robotyka nie zastępują maszyn czy urządzeń, ale zmienia i ingeruje bezpośrednio w proces wytwarzania. Optymalizuje układy cięcia tkanin, zszywa i łączy tkaniny o różnych fakturach, tradycyjne liniały wspomaga cyfrowo. Zintegrowanie ovelok, stebnowki z AI wykrywają defekty, automatycznie dopasowuje parametry. Inteligentne żelazka z sensorami dostosowują temperaturę do tkaniny, roboty prasujące przewidują zagniecenia na podstawie skanów 3D. W Tabeli 4 zostały zaprezentowane przykładowe, obecnie funkcjonujące na rynku rozwiązania AI wspomagające pracę krawca i funkcjonowanie zakładu krawieckiego na rynku.

Tabela 4. Rozwiązania AI dla krawiectwa – korzyści dla krawca i procesu/firmy

Program	Charakterystyka	Korzyści – efektywność pracy krawca	Korzyści – konkurencyj- ność procesu/firmy
Mobile Tailor bt 3DLOOK	Do skanowania ciała, generuje precyzyjny model ciała 3D ciała i ponad 80 pomiarów.	Eliminuje potrzebę fizycznych spotkań krawca z klientem – redukuje błędy pomiarowe i koszty poprawek.	Oferowanie usług online, mniejsza ilość zwrotów i kosztów ich obsługi, szybsza realizacja zamówień.
Pattarina/ MakeristAR	Do projekcji wzorów na tkaninę – wyświetla szablon w dokładnej skali na ekranie telefonu.	Bez konieczności tworzenia papierowych szablonów – przenosi wzory bezpośrednio na tkaninę.	Niższe koszty materiałowe ze względu na brak lub minimalizację odpadów produkcyjnych, łatwiejsze zmiany w projekcie.
YOLOv8- based defect detection	Model maszynowego uczenia się do automatycznego wykrywania defektów szwów.	Detekcja małych błędów z dokładnością 95%, redukcja błędów ludzkich w kontroli jakości.	Wyższa jakość produktów finalnych, mniejsza ilość zwrotów i koszty ich obsługi.
Soft Wear Automation	Roboty z automatyczną manipulacją tkaniną, dostosowują się do zniekształceń w czasie rzeczywistym, szują bez udziału operatora.	Precyzja szycia, pełna automatyzacja szycia, redukcja kosztów pracy.	Konkurencyjna cena przy wysokiej jakości szycia, budowanie marki i możliwość skalowania produkcji bez wzrostu kosztów.

Program	Charakterystyka	Korzyści – efektywność pracy krawca	Korzyści – konkurencyj- ność procesu/firmy
Eisen Automated Iron	Automatyczny robot prasujący, aplikacja steruje metodami prasowania.	Całkowita automatyzacja, niebezpieczna, profesjonalny efekt bez wilgoci.	Stąła jakość, szybkie wykańczanie wyrobów.
CLO 3D	Symulacja 3D, realistyczna fizyka tkanin, wirtualne przymiarki, edycja szablonów z aktualizacją 3D.	Precyzyjne dopasowanie do manekinów fizycznych.	Szybkie wprowadzanie nowych kolekcji, możliwość prezentacji klientom wizualizacji 3D przed produkcją, mniejsze zużycie materiałów.
Browzwear (V sitcher)	AI do konwersji szkiców, tekstów w 3D modele, automatyczne szycie, optymalizacja rozkroju.	Szybkie prototypy, integracja z produkcją.	Niższe koszty rozwoju kolekcji, integracja z procesem produkcji.

Źródło: opracowanie własne na podstawie: YOLOv8-based defect detection, b.d.; 3DLOOK, b.d.; Pattarina, b.d.; Soft Wear Automation, b.d.; Eisen Innovations, b.d.; CLO 3D, b.d.; Browzwear, b.d.

Wprowadzenie narzędzi AI do procesu produkcji ubrań i pracy krawca dają szansę małym i średnim pracowniom konkurować z masowymi producentami przede wszystkim w obszarze niższych kosztów, wysokiej jakości przy zachowaniu personalizacji, szybszej realizacji zamówienia, a także możliwość szybkiego wdrożenia nowych kolekcji lub wprowadzenia nowych usług takich jak wirtualne przymiarki. W efekcie krawiec nie tylko zwiększa efektywność swojej pracy, ale także zmienia pozycję firmy na rynku, dając jej możliwość rozszerzenia skali z lokalnej do ogólnopolskiej czy międzynarodowej. McKinsey szacuje, że generatywna sztuczna inteligencja mogłaby zwiększyć zyski operacyjne w sektorach mody, odzieży i luksusu nawet 275 miliardów do 2028 roku.

W raporcie McKinsey&BoF „The state of fashion 2025: when the rules change” z listopada 2025, autorzy stwierdzają, że „w obliczu burzliwych warunków, w tym zmiennych kosztów surowców, zakłóceń w łańcuchu dostaw i powolnego wzrostu, które obciążają model ekonomiczny branży mody, AI przechodzi z przewagi konkretyjnej w konieczność biznesową” (McKinsey, 2025, s. 3).

Jednak sztuczna inteligencja w krawiectwie to nie tylko korzyści, ale także dylematy natury etycznej, ekonomicznej i technologicznej takie jak:

- ryzyko utraty pracy przez osoby zatrudnione przy wykonywaniu rutynowych zadań, np. przy szyciu, rozkroju,
- konieczność zdobycia nowych zaawansowanych technologicznie kompetencji,
- inwestycja w drogi sprzęt, oprogramowania i szkolenia,
- AI nie zastąpi intuicji ludzkiej,
- awarie systemów czy brak prądu przy pełnej zależności od maszyn, urządzeń i technologii oznacza paraliż produkcji i zagraża realizacji zamówień, skutkuje karami za niewykonanie zleceń i zagraża pozycji firmy.

W XXI wieku ważnym wyzwaniem tradycyjnego krawiectwa są: inteligentne materiały i tekstylia. Ubrania, które reagują na temperaturę, wilgotność, światło, nacisk, ruch, zawierają czujniki, przewodzące włókna, mikroelektronikę, potrafią zamieniać swoje właściwości (kolor, izolację, sztywność). AI umożliwia tkaninom automatyczne dostosowanie się do warunków środowiskowych i potrzeb użytkowników poprzez regulację takich właściwości jak temperatura termoregulacje, wodoodporność oddychalność i elastyczność, monitorowanie parametrów życiowych. Aby pracować z inteligentnymi tekstyliami, będzie potrzebna wiedza taka jak przewodzenie nici i włókna, praca z czujnikami i mikrokontrolerami, interpretacja danych z czujników personalizacja działania materiału, umiejętność pracy z tkaninami reaktywnymi i hybrydowymi to nowe obszary kompetencji krawca. Inteligentne materiały to także wyzwanie technologiczne obok tradycyjnych wymagane będą linie do pracy z materiałami bezszwowymi, nicią przewodzącą, stanowiska montażowe, aby stworzyć ubranie będące systemem, łączące materiał z użytkownikiem i oprogramowaniem (Dejene, 2025).

Wyniki badań empirycznych – AI w zakładzie krawieckim

Badanie pilotażowe miało charakter mieszany ilościowo-opisowy z elementami analizy jakościowej (badanie ankietowe). Zastosowano kwestionariusz ankiety własnego autorstwa, składający się z 11 pytań zamkniętych (skale nominalne i porządkowe, wybór wielokrotny) oraz 2 pytań otwartych

o charakterze uzupełniającym. Narzędzie, które skonstruowano specjalnie na potrzeby niniejszego badania eksploracyjnego, składa się z:

- pytań demograficznych (forma prawna, rok rozpoczęcia działalności, liczba zatrudnionych, specjalizacja, zasięg),
- pytań dotyczących wiedzy i postaw wobec sztucznej inteligencji (5-stopniowa skala samooceny wiedzy, źródła wiedzy, wykorzystanie AI),
- pytań o bariery wdrożenia i ocenę potencjału AI (z wyborem wielokrotnym, pojedynczym, skalą porządkową).

Kwestionariusz nie przeszedł pełnej formalnej walidacji psychometrycznej (trafności i rzetelności α Cronbach), co wynika z eksploracyjnego charakteru badania pilotażowego w wąskiej branży. Przyjęto założenie, że narzędzie mierzy deklaratywne postawy i zachowania respondentów w sposób wystarczający do wstępnej identyfikacji trendów w wąskiej grupie branżowej. Ograniczeniem badania jest niewątpliwie brak pełnej analizy rzetelności i trafności konstrukcyjnej, co wynika przede wszystkim z małej liczebności próby $N=57$, uniemożliwiającej wiarygodne zastosowanie klasycznych procedur psychometrycznych. Przeprowadzono jedynie wstępną ocenę trafności treściowej metodą ekspercką – kwestionariusz ocenili 3 eksperci (2 praktyków branży krawieckiej oraz 1 socjolog). Obliczony średni współczynnik Content Validity Ratio (CVR) wyniósł 0,78 co wskazuje na zadawalającą trafność treściową w warunkach pilotażu. Ze względu na charakter pytań (głównie kategoriowe i wielokrotnego wyboru) nie obliczono współczynnika α Cronbacha dla całej skali. Dla bloku pytań o bariery wdrożenia AI (traktowanego jako wskaźnik binarny) wstępną spójność wewnętrzną mierzona współczynnikiem Kuder-Richardson 20 wyniósł 0,64, co wskazuje że spójność wewnątrz w badaniu eksploracyjnym jest akceptowalna. Wyniki należy traktować jako wstępne i wymagające potwierdzenia w badaniach na większej, reprezentatywnej próbie.

Celem badania pilotażowego było zdefiniowanie roli sztucznej inteligencji w działalności krawieckiej badanej grupy, głównych trendów, opinii na temat stosowanej dotychczas technologii i możliwości jakie daje sztuczna inteligencja. Próba badawcza została dobrana celowo, co jest typowe dla badań branżowych o ograniczonym dostępie do populacji. W badaniu ostatecznie wzięło udział 57 osób prowadzących działalność gospodarczą w branży krawieckiej z dwóch województw: dolnośląskiego (45 osób – 79%) i lubuskiego (12 osób – 21%).


Badanie pilotażowe przeprowadzono w okresie lipiec-listopad 2025, za pomocą ankiety w wersji „papierowej”, dystrybuowanej przez kontakty bezpośrednie, wypełnianej przez właścicieli lub osoby decyzyjne. Ze względu na dobór celowy i małą liczebność próby ($N=57$), wyniki nie mogą być uogólniane na całą populację polskich krawców. Badanie ma charakter eksploracyjny i pilotażowy – służy identyfikacji postaw, trendów i barier wdrożenia AI w działalności krawieckiej.

Obszary badawcze obejmowały następujące kwestie w branży krawieckiej:

- poziom wiedzy o AI,
- źródła wiedzy o nowych technologiach,
- stopień i zakres wykorzystania narzędzi AI,
- obszary zastosowania AI,
- bariery wdrożenia AI,
- korzyści z technologii – wpływ AI na efektywność pracy,
- korzyści z technologii – wpływ AI na konkurencyjność firmy,
- przyszłość firm łączących rzemiosło z technologią cyfrową,
- szkolenia z tematyki AI.

Wyniki prezentują odpowiedzi 57 respondentów. Dane opisano za pomocą statystyk opisowych (częstości, procenty). Ze względu na charakter pytań (głównie nominalny i porządkowy) nie stosowano testów parametrycznych; w razie analizy zależności między zmiennymi raportowano pełne parametry, np. $X^2(df, N)$, wartość X^2 , p , V Cramera jako miarę efektu).

Analizując profil respondentów (Rysunek 2), warto zauważyć, że próba jest zdominowana przez właścicieli jednoosobowych działalności gospodarczych, najczęściej z ponad 25-cio letnim doświadczeniem w prowadzeniu działalności gospodarczej, zazwyczaj rodzinnych, mające ogólnopolski zasięg działania i zatrudniających dodatkowo 2-3 pracowników. Wśród respondentów była zauważona względna proporcja 31 mężczyzn i 26 kobiet, najczęściej w wieku do 60 roku życia 40 respondentów (70% badanych), a 17 osób (30% badanych) od 27 do 59 lat. Profil prowadzonej działalności gospodarczej badanych zakładów i pracowni krawieckich obejmuje przede wszystkim szycie ubrań, ale także projektowanie ubrań, naprawy.



Rysunek 2. Profil podmiotów reprezentujących próbę badawczą

Źródło: opracowanie własne.

Analizując poziom wiedzy respondentów na temat AI, jest on raczej niski, ponieważ większość 82,5% ma jedynie podstawową świadomość, że istnieje taka technologia, a jedyni i tylko 17,6% aktywnie korzysta lub rozumie AI głębiej, co wskazuje na dużą lukę edukacyjną w branży krawieckiej. Główne źródła wiedzy są pasywne (Internet, artykuły branżowe, media społecznościowe), a aktywne formy (takie jak: szkolenia, rozmowy) są w badanej grupie rzadkie. Dodatkowo 10 osób nie interesuje się tematem, co koreluje także z niskim poziomem wiedzy na temat sztucznej inteligencji.

Aktualnie wykorzystywane są najczęściej aplikacje biurowe, komunikatory, ale także programy graficzne i do projektowania. Użycie narzędzi AI jest niskie, ale jeśli połączyć to z deklaracją otwartości na AI w przyszłości daje przewagę 64,9%. Największe zainteresowanie budzą dwa obszary takie jak: generowanie projektów i wirtualne przymiarki, które związane są z kreatywnym i praktycznym wykorzystaniem AI w e-commerce. Wśród barier AI dominują brak wiedzy technologicznej, ale także bariery kompetencyjne i finansowe. Wybór największych barier potwierdza wcześniejsze wskazania ponieważ respondenci ponownie wskazali brak wiedzy, a także dodatkowo koszty. Zarówno w przypadku wpływu AI na efektywności pracy jak i konkurencyjność firmy respondenci wykazywali wyraźnie pozytywne postawy (ponad 60% respondentów udzieliło odpowiedzi w kategoriach pozytywnych).

Test chi- kwadrat potwierdził, że rozkłady odpowiedzi znacząco odbiegają od rozkładu równomiernego na korzyść ocen pozytywnych: $\chi^2(4) = 26,77$, $p < 0,001$ (wpływu na efektywności pracy) oraz $\chi^2(4) = 26,998$, $p < 0,001$ (wpływu na konkurencyjność). Podobnie pozytywnie oceniano przyszłość firm krawieckich łączących tradycyjne rzemiosło z technologią cyfrową (ponad 64% wskazań „duży” lub „bardzo duży” potencjał) oraz wyrażano wysokie zainteresowanie szkoleniami z zakresu zastosowania AI w branży (65% odpowiedzi „zdecydowanie tak” lub „raczej tak”). Tabela 5 zawiera uzyskane odpowiedzi w odniesieniu do postawionych hipotez.

Tabela 5. Wyniki badań w grupie pilotażowej pracowni krawieckiej

Hipoteza	Status weryfikacji	Uzasadnienie
H1: większość właścicieli małych pracowni krawieckich ma niski poziom wiedzy o sztucznej inteligencji	Hipoteza została potwierdzona na poziomie deklaracji respondentów	<p>Samooocena poziomu wiedzy na temat sztucznej inteligencji:</p> <ul style="list-style-type: none"> • Wiem tylko, że takie rozwiązania istnieją = 14 (24,6%), • Znam ogólne pojęcie = 16 (28,1%), • Znam przykłady zastosowań AI = 17 (29,8%), • Korzystam z narzędzi AI w pracy = 7 (12,3%), • Rozumiem zasady działania i wdrażania AI = 3 (5,3%). <p>Źródło wiedzy o nowych technologiach (w tym AI) (wybór wielokrotny):</p> <ul style="list-style-type: none"> • Nie interesuje się tym tematem = 10, • Media społecznościowe = 17, • Internet/artykuły branżowe = 18, • Szkolenia/kursy = 6, • Od innych przedsiębiorców = 6.
H2: im większa skala działalności, tym większe prawdopodobieństwo wykorzystania narzędzi	Widoczna jest tendencja, jednak związek nie jest statystycznie istotny	<p>Aktualne wykorzystanie narzędzi cyfrowych w działalności krawieckiej:</p> <ul style="list-style-type: none"> • Programy do projektowania typu CAD/CAM = 31, • Programy graficzne (Canva, Corel, Adobe) = 32, • Aplikacje biurowe (Word, Excel, itp.) = 47, • Komunikatory/Social media do obsługi klientów = 47. <p>Wykorzystywanie narzędzi opartych na AI w działalności:</p> <ul style="list-style-type: none"> • Tak, regularnie = 7 (12,3%), • Sporadycznie = 10 (17,5%), • Testowaliśmy = 6 (10,5%), • Nie, ale planujemy = 14 (24,6%), • Nie planujemy = 20 (35,1%). <p>Obszary wykorzystania AI – obecne lub potencjalne (wybór wielokrotny):</p> <ul style="list-style-type: none"> • Generowanie projektów i wzorów ubrań = 26, • Analiza danych o klientach /materiałach = 12, • Tworzenie treści promocyjnych = 12, • Wirtualne przymiarki i dopasowanie rozmiarów = 20, • Automatyczne planowanie i przypomnienia = 3, • Nie wykorzystuje AI = 22.

Hipoteza	Status weryfikacji	Uzasadnienie
H3: główne bariery wdrożenia AI to brak wiedzy technicznej i wysokie koszty inwestycji	Hipoteza została w pełni potwierdzona	<p>Bariery utrudniające wdrożenia AI w działalności (wybór wielokrotny):</p> <ul style="list-style-type: none"> • Brak wiedzy technologicznej = 36, • Wysokie koszty wdrożenia = 33, • Brak czasu na naukę = 24, • Obawa przed technologią = 15, • Brak odpowiednich narzędzi na rynku = 11, • Brak potrzeby = 13. <p>Największa bariera wdrożenia AI według respondentów:</p> <ul style="list-style-type: none"> • Brak wiedzy = 24 (42,1%), • Koszty = 20 (35,1%), • Brak czasu = 8 (14%), • Niepewność efektów = 4 (7%), • Inne = 1 (1,8%).
H4: stosowanie AI w projektowaniu ubrań zwiększa efektywność i konkurencyjność pracowni	Hipoteza została potwierdzona na poziomie postaw i oczekiwań respondentów, jednak ze względu na brak walidacji narzędzia nie można wnioskować o rzeczywistym wpływie AI	<p>Ocena potencjalnego wpływu AI na efektywność pracy w krawiectwie:</p> <ul style="list-style-type: none"> • Bardzo negatywny = 1 (1,8%), • Raczej negatywny = 5 (8,8%), • Neutralny = 16 (28,1%), • Raczej pozytywny = 23 (40,4%), • Bardzo pozytywny = 12 (21,1%), <p>Wpływ wykorzystania AI na zwiększenie konkurencyjności firmy:</p> <ul style="list-style-type: none"> • Zdecydowanie nie = 2 (3,5%), • Raczej nie = 6 (10,5%), • Trudno powiedzieć = 14 (24,6%), • Raczej tak = 22 (38,6%), • Zdecydowanie tak = 13 (22,8%).
H5: krawiectwo łącząc tradycyjne rzemiosło z cyfrowymi narzędziami ma większy potencjał rozwoju w przyszłości	Hipoteza została potwierdzona na poziomie percepcji badanych (deklaratywnie)	<p>Ocena przyszłości firm krawieckich łączących rzemiosło z technologią cyfrową:</p> <ul style="list-style-type: none"> • Brak przyszłości = 1 (1,8%), • Niewielki potencjał = 5 (8,8%), • Umiarkowany potencjał = 14 (24,6%), • Duży potencjał = 24 (42,1%), • Bardzo duży potencjał = 13 (22,8%). <p>Zainteresowanie szkoleniem z zakresu AI dla krawiectwa</p> <ul style="list-style-type: none"> • Tak, zdecydowanie = 16 (28,1%), • Raczej tak = 21 (36,8%), • Nie mam zdania = 10 (17,5%), • Raczej nie = 7 (12,3%), • Zdecydowanie nie = 3 (5,3%).

Źródło: opracowanie własne.

Ze względu na brak pełnej walidacji psychometrycznej kwestionariusza (ograniczona rzetelność wewnętrzna KR-20 ok. 0,64) oraz brak analizy czynnikowej, wyniki niniejszego badania należy potraktować jako wstępne i pilotażowe. Weryfikacja hipotez opiera się przede wszystkim na analizach opisowych oraz deklaracjach respondentów:

- Hipoteza H1 zostało częściowo potwierdzona. Wiedza o AI wśród właścicieli pracowni jest ograniczona a dominują podstawowe narzędzia biurowe, a świadomość bardziej zaawansowanych rozwiązań AI jest niska.
- Hipoteza H2 została częściowo potwierdzona. Zależność nie jest statystycznie istotna, ale widoczny jest kierunek tendencji: większe podmioty są bardziej skłonne do inwestowania w technologie AI i cyfrowe narzędzia pracy.
- Hipoteza H3 została w pełni potwierdzona. Koszty i brak kompetencji technicznych stanowią kluczowe bariery utrudniające wdrożenie technologii AI w małych pracowniach krawieckich.
- Hipoteza H4 została potwierdzona na poziomie postaw, wskazując, że 61% respondentów ocenia wpływ AI na efektywność i konkurencyjność firmy pozytywnie. Ze względu na deklaracyjny charakter odpowiedzi – nie można jednak wyciągnąć wniosków o rzeczywistym wpływie AI na wyniki ekonomiczne pracowni. Respondenci uznają, że zastosowanie AI w projektowaniu i wizualizacji zwiększa efektywność pracy, przyspiesza realizację zleceń i pozwala lepiej komunikować projekty z klientami.
- Hipoteza 5 została potwierdzona – wyniki sugerują że tradycyjne rzemiosło, wzbogacone o cyfrowe technologie i AI, ma największe szanse rozwoju i utrzymania konkurencyjności pracowni krawieckich na rynku. Większość badanych 64,9% widzi duży lub bardzo duży potencjał w modelu łączącym tradycyjne rzemiosło z technologią cyfrową, a 65% wyraża zainteresowanie szkoleniami z AI.

Wyniki wskazują, że w badanej grupie nie występuje ideologiczny opór przed sztuczną inteligencją, a główną przeszkodą przez powszechnym jej stosowaniem jest brak praktycznej wiedzy, który jednocześnie obniża gotowość do wdrożenia i ogranicza ocenę potencjalnych korzyści. Wiedza wydaje się kluczowym czynnikiem różnicującym postawy – respondenci o wyższym poziomie wiedzy częściej korzystają z AI i wyżej oceniają jego wpływ.

Szczególna ostrożność jest wymagana przy interpretacji hipotez H1, H4 i H5, które dotyczą samooceny wiedzy oraz subiektywnej oceny wpływu i potencjału AI. Mimo tych ograniczeń uzyskane wyniki wskazują na spójny obraz postaw badanych przedsiębiorców z branży krawieckiej i stanowią podstawę do dalszych, bardziej pogłębionych badań na większej próbie.

Do oceny siły związku, istotności statycznej oraz ich praktycznego znaczenia uzyskanych w badaniu wyników zostały wyznaczone: Rho Spearman dla par zmiennych porządkowych (takich jak: poziom wiedzy, ocena wpływu AI), a V Cramera dla par zmiennych nominalnych (takich jak wykorzystanie AI, bariery). Tabela 6 prezentuje wybrane i najistotniejsze wyniki.

Tabela 6. Związki między wybranymi zmiennymi dotyczącymi wiedzy, wykorzystania i postrzegania sztucznej inteligencji w badanych firmach

Związki	Wyniki testów
Między „wpływem AI na efektywność działania” a „wpływem AI na konkurencyjność firmy”	Rho=0,71; $p<0,001$ Im silniej respondenci postrzegali pozytywny wpływ AI na efektywność działania, tym wyższej oceniali jego wpływ na konkurencyjność firmy.
Między „wpływem AI na konkurencyjność” a „przyszłość firm łączących rzemiosło z technologią”	Rho=0,68; $p<0,001$ Wyższa ocena wpływu AI na konkurencyjność współwystępowała z większym optymizmem co do przyszłości hybrydowych modeli biznesowych.
Między „poziom wiedzy AI” a „aktualny poziom wykorzystania AI”	Rho=0,62; $p<0,001$ Osoby deklarujące wyższy poziom wiedzy częściej i intensywniej wykorzystywały narzędzia AI w praktyce.
Między „poziom wiedzy AI” a „wpływ AI na efektywność działania”	Rho=0,45; $p<0,001$ Osoby deklarujące wyższy poziom wiedzy były częściej przekonane o wpływie AI na efektywność działania.
Między „najważniejsza bariera” a „wykorzystanie AI”	V Cramera =0,48; $p<0,001$ umiarkowany związek
Między „najważniejsza bariera” a „zainteresowanie szkoleniem”	V Cramera =0,42; $p<0,001$ umiarkowany związek
Między „źródło wiedzy” a „poziom wiedzy o AI”	V Cramera =0,37; $p<0,001$ umiarkowany związek

Źródło: opracowanie własne.

W badanej grupie pilotażowej panuje zgoda, że praktyczne wymiary zastosowania narzędzi AI takie jak szybkie projektowanie, ograniczenie kosztów, wzrost efektywności procesów są dźwignią zarówno konkurencyjności firm

polskich jak i przyszłości branży. Optymistyczne postrzeganie przyszłości firm, łączących tradycje i nowoczesnością – wiąże się z długoterminową wizją konkurencyjności badanych firm i branży. W branży zatem nie ma ideologicznego oporu przed AI, raczej na co wskazywali w dwóch odpowiedziach brak wiedzy praktycznej jak wykorzystać AI w krawiectwie. Wiedza decyduje o tym, że jedni respondenci już z korzystają z AI a inni nie. Deklarowana bariera „brak wiedzy jest realną barierą. Osoby mające wiedzę praktyczną i znające możliwości AI wyżej oceniają wpływ AI na efektywność. Wiedza zatem redukuje obawy, daje sprawczość i motywuje do przełożenia poznanych rozwiązań na działalność operacyjną pracowni krawieckich. Brak wiedzy to główna bariera wykorzystania AI, która jest realnym problemem dla badanych firm. Firmy są zmotywowane do udziału w szkoleniach, zainteresowane i świadome że nowa technologia jaką jest AI przekłada się i na efektywność pracy krawca jak również konkurencyjność firm. Aktywne i pasywne źródła informacji mają realny wpływ na wiedzę o AI wśród respondentów.

Branża krawiecka jest już cyfrowa (wysokie użycie CAD, grafiki, social media), postrzega AI jako szansę na przyszłość co ułatwia potencjalne wdrożenia. Doświadczeni przedsiębiorcy, którzy dominują w badanej próbie wykazują zaniepokojenie o koszty i czas, ale jednocześnie optymizm i zrozumienie dla rozwoju technologii AI.

Ze względu na ograniczenia próby (mała liczebność, dobór celowy, tylko dwa województwa) wnioski mają wstępny charakter i wymagają potwierdzenia w większym, reprezentatywnym badaniu. Nie należy ich traktować jako uogólnienia na całą branżę w Polsce – wyniki sugerują trendy ale nie pozwalają na wnioskowanie przyczynowe ani generalizację, wymagają replikacji w większej, losowej próbie.

Wnioski

Sztuczna inteligencja w krawiectwie stanowi przykład transformacji działalności rzemieślniczej i usługowej do cyfrowej i inteligentnej, gdzie granice między technologią, ekonomią i estetyką ulegają zatarciu. Integracja AI umożliwia nie tylko automatyzację, ale także emocjonalne i kulturowe dopasowanie produktów do konsumenta, co w dłuższej perspektywie może prowadzić do powstawania bardziej świadomej i zrównoważonej gospodarki modowej.

Przeprowadzone badanie, mimo pilotażowego charakteru, pozwoliło osiągnąć założony cel. Uzyskane wyniki wskazują, że sztuczna inteligencja posiada istotny potencjał w krawiectwie, przede wszystkim poprzez odciążenie krawców od rutynowych i powtarzalnych zadań co może przyczynić się do bardziej efektywnego wykorzystania zasobów ludzkich i wzrostu produktywności. Branża krawiecka stoi obecnie na progu transformacji technologicznej. Respondenci wykazali w większości pozytywne nastawienie do sztucznej inteligencji, postrzegając ją nie jako zagrożenie dla tradycyjnego rzemiosła, lecz jako narzędzie wzmacniające jego efektywność, konkurencyjność i zrównoważony rozwój. Jednocześnie wyniki wyraźnie podkreślają istotną barierę w postaci braku wiedzy i praktycznych doświadczeń z narzędziami AI. Należy jednak pamiętać, że ze względu na ograniczenia metodyczne – w szczególności brak pełnej walidacji psychometrycznej kwestionariusza oraz małą, celowo dobraną próbę – powyższe wnioski mają charakter wstępny i orientacyjny. Niemniej jednak wskazują one na wyraźne zapotrzebowanie branży na interwencje szkoleniowe i edukacyjne w zakresie zastosowania sztucznej inteligencji w krawiectwie.

Branża zmierza w stronę krawiectwa cyfrowego smart połączenia tradycji rzemieślniczej z technologiami przyszłości, co zwiększa konkurencyjność i przyciąga młodsze pokolenie klientów. AI to uzupełnienie tradycyjnego krawiectwa – w dużych fabrykach rewolucjonizuje produkcję, w małych pracowniach pomaga w projektowaniu i optymalizacji. AI pojawia się w ubraniach smart zarówno na etapie projektowania jak i analizie danych. Inteligentne ubrania i tekstylia nie zastąpią krawcy, zmieniają jego pracę o np. integrację czujników, programowanie, testy, personalizację, czyli tworzenia systemów (Piwowar i in., 2023, s. 10).

Najistotniejszym ograniczeniem przeprowadzonego badania pilotażowego była mała liczebność próby badawczej $N=57$ podmiotów sektora MSP, zdominowana przez tradycyjne, i doświadczone przedsiębiorstwa reprezentujące „przeciętnie innowacyjne” pracownie krawieckie a nie zaawansowane technologicznie krawieckie start-upy. W efekcie uzyskane wyniki odnoszą się przede wszystkim do segmentu małych pracowni krawieckich i nie mogą być uogólniane bezpośrednio na wysoko innowacyjne start-upy krawieckie ani duże podmioty branżowe. Dalsze badania powinny koncentrować się na sprawdzeniu w jaki sposób sztuczna inteligencja ma wpływ na trendy rynkowe,

ich prognozowanie, popyt na produkty lub ceny surowców, a tym samym odpowiednie planowanie produkcji, zapasów, strategii marketingowej i innych aspektów operacyjnych, aby się lepiej przygotować na zmienne warunki rynkowe.

Literatura

1. Aishwariya, S. (2019). *Fast Fashion vs Slow Fashion*. Pobrane z: <https://www.fibre2fashion.com/industry-article/author/s-aishwariya/368> (dostęp: 28.12.2025).
2. Biznes Newseria.pl. (2025). *W ciągu roku w Polsce ubyło 500 przedsiębiorstw odzieżowo-tekstylnych. Problemem są spadki zamówień z Europy Zachodniej i wzrost kosztów*. Pobrane z: <https://biznes.newseria.pl/news/w-ciagu-roku-w-polsce,p2056397932> (dostęp: 28.12.2025).
3. Browzwear. (b.d.). *V-stitcher*. Pobrane z: <https://browzwear.com/products/v-stitcher> (dostęp: 28.12.2025).
4. Brożyna, G., Kossakowska-Jarosz, K. (2016). *Manuskrypt cechu krawców ze zbiorów archiwum państwowego w Opolu. Edycja krytyczna*. Archiwum Państwowe w Opolu.
5. Centobelli, P., Abbate, S., Nadeem, S. P., Garza-Reyes, J. A. (2022). Slowing the fast fashion industry: an all-round perspective. *Current Opinion in Green and Sustainable Chemistry*, 38, 100684. <https://doi.org/10.1016/j.cogsc.2022.100684>
6. CLO 3D. (b.d.). *CLO 3D*. Pobrane z: <https://www.clo3d.com/en> (dostęp: 28.12.2025).
7. Dejene, B. K. (2025). The future of fabric: a comprehensive review of self-powered smart textiles and their emerging applications. *Energy Reports*, 14, 898-943. <https://doi.org/10.1016/j.egyr.2025.07.002>
8. Eisen Innovations. (b.d.). *Eisen automated iron*. Pobrane z: <https://eiseninnovations.com> (dostęp: 28.12.2025).
9. Fortune Business Insights. (2025). *Apparel market*. Pobrane z: <https://www.fortunebusinessinsights.com/apparel-market-110718> (dostęp: 28.12.2025).
10. Gofin.pl. (b.d.). *Produkcja odzieży*. Pobrane z: <https://klasyfikacje.gofin.pl/pkd/5,2,1446,produkcja-odziezy.html> (dostęp: 28.12.2025).
11. Mapa Karier. (2022). *Zawód: Krawiec*. Pobrane z: <https://mapakarier.org/sciezki-kariery/204/m/krawiec/> (dostęp: 28.12.2025).

12. McKinsey&Company. (2025). *The State of Fashion 2025*. Pobrane z: <https://www.mckinsey.com/~media/mckinsey/industries/retail/our%20insights/state%20of%20fashion/2025/the-state-of-fashion-2025-v2.pdf> (dostęp: 28.12.2025).
13. Ministerstwo Edukacji Narodowej. (b.d.a), *Odbudowa Multimodalna Doradztwa zawodowego, Zawód: krawiec (753105)*. Pobrane z: <https://infozawodowe.men.gov.pl/uploads/pdf/b429a3f349c65232aa49b5edef8cc342.pdf> (dostęp: 28.12.2025).
14. Ministerstwo Edukacji Narodowej. (b.d.b). *Zawód: krawiec (753105)*. Pobrane z: https://infozawodowe.men.gov.pl/image/professionCoreCurriculum/krawiec_e133af079a64f1d038c23045d41592f2.pdf (dostęp: 28.12.2025).
15. Nowakowski, M. (2025). *Branża odzieżowa w Polsce – dane, statystyki i problemy rynku modowego*. Pobrane z: <https://brandly360.com/pl/blog/branza-odziezowa-w-polsce-dane-statystyki-i-problemy-rynku-modowego> (dostęp: 28.12.2025).
16. Parlament Europejski. (2020). *Sztuczna inteligencja: co to jest i jakie ma zastosowania?*. Pobrane z: <https://www.europarl.europa.eu/topics/pl/article/20200827STO85804/sztuczna-inteligencja-co-to-jest-i-jakie-ma-zastosowania> (dostęp: 28.12.2025).
17. PARP. (2020). *Raport: Identyfikacja instrumentów wsparcia dla rozwoju sektora przemysłu mody i innowacyjnych tekstyliów*. Pobrane z: <https://www.parp.gov.pl/publikacje/publication/identyfikacja-instrumentow-wsparcia-dla-rozwoju-sektora-przemyslu-mody-i-innowacyjnych-tekstyliow> (dostęp: 28.12.2025).
18. PARP. (2023). *Moda nadal modna – PARP publikuje najnowszy raport na temat branży*. Pobrane z: <https://www.parp.gov.pl/component/content/article/84925:moda-nadal-modna-parp-publikuje-najnowszy-raport-na-temat-branzy> (dostęp: 28.12.2025).
19. Pattarina. (b.d.). *Pattarina*. Pobrane z: <https://www.pattarina.de> (dostęp: 28.12.2025).
20. Piwowar, K., Jakubik, Z., Czernicka, J. (2023). *Zastosowanie sztucznej inteligencji w gospodarce. Przegląd wybranych inicjatyw i technologii z rekomendacjami dla przedsiębiorców*. Raport tematyczny nr 3. PARP.
21. PKO BP. (2025). *Rynki międzynarodowe: Odzież. Sytuacja bieżąca i prognozy do 2029*. Pobrane z: <https://centrumanaliz.pkobp.pl/rynki-zagraniczne/>

- branza-odzieżowa-sytuacja-bieżąca-i-prognozy-rozwoju-rynku-do-2029 (dostęp: 28.12.2025).
22. PWN. (b.d.) *Krawiectwo*. Pobrane z: <https://sjp.pwn.pl/slowniki/krawiectwo.html> (dostęp: 28.12.2025).
 23. Soft Wear Automation. (b.d.). *Soft Wear Automation*. Pobrane z: <https://softwearautomation.com> (dostęp: 28.12.2025).
 24. Soly, H. (2008). The political economy of European craft guilds: power relations and economic strategies of merchants and master artisans in the medieval and early modern textile industries. *International Review of Social History*, 53, 45-71. <https://doi.org/10.1017/S002085900800360X>
 25. Ustawa o rzemiośle z dnia 22 marca 1989 r. (Dz.U. z 1989 r. Nr 17, poz. 92).
 26. Warade, P. (2025). *AI in fashion market size & outlook, 2025-2033*. Pobrane z: <https://straitresearch.com/report/ai-in-fashion-market> (dostęp: 28.12.2025).
 27. Wielkopolska Izba Rzemieślnicza. (b.d.). *Alfabetyczny wykaz zawodów*. Pobrane z: <https://www.irpoznan.com.pl/userfiles/files/oswiata%202018/lista%20zawod%C3%B3w%20pdf.pdf> (dostęp: 28.12.2025).
 28. YOLOv8-based defect detection. (b.d.). *YOLOv8-based defect detection. Hugging Face*. Pobrane z: <https://huggingface.co/kesimeg/yolov8n-clothing-detection> (dostęp: 28.12.2025).
 29. ZPE. (b.d.). *E-materiały do kształcenia zawodowego, Podstawy krawiectwa pomocnika krawca*. Pobrane z: <https://zpe.gov.pl/a/przybory-i-narzedzia-krawieckie> (dostęp: 28.12.2025).
 30. 3DLOOK. (b.d.). *Mobile Tailor*. Pobrane z: <https://3dlook.ai/mobile-tailor> (dostęp: 28.12.2025).



ISBN 978-83-68103-36-6