

# Cybersecurity and Law

2026 Nr 1(15)

DOI: 10.34567/cal/220503



## **Automatyzacja wydawania postanowień wojewódzkiego sądu administracyjnego przy użyciu sztucznej inteligencji – analiza skuteczności aplikacji wydającej postanowienia sądu administracyjnego na podstawie art. 58 p.p.s.a.**

## **Automation of administrative court orders using artificial intelligence – an analysis of the effectiveness of an application issuing administrative court orders on the basis of article 58 of the law on proceedings before administrative courts**

**Agnieszka SKÓRA**

Uniwersytet Warmińsko-Mazurski w Olsztynie

ORCID: 0000-0003-2169-5326

E-mail: agnieszka.skora@uwm.edu.pl

**Aleksandra Nikola MROCZKOWSKA**

Uniwersytet Warmińsko-Mazurski w Olsztynie

ORCID: 0009-0001-6233-7640

E-mail: aleksandra.mroczkowska.2@student.uwm.edu.pl

### **Streszczenie**

Celem opracowania jest ustalenie, czy wykorzystanie sztucznej inteligencji do weryfikacji przesłanek odrzucenia skargi określonych w art. 58 p.p.s.a. może stanowić rzeczywiste i prawnie dopuszczalne wsparcie działalności orzeczniczej wojewódzkich sądów administracyjnych. Na potrzebę pracy zaprojektowano i zaimplementowano aplikację webową opartą na modelu językowym analizującym treść skarg oraz generującym projekt postanowienia sądu z uzasadnieniem. Ewaluacja wykazała techniczną wykonalność algorytmicznej klasyfikacji w ograniczonym zakresie oraz ujawniła strukturalne bariery wynikające z niepełności danych tekstowych. Wnioskiem pracy jest dopuszczalność wykorzystania AI wyłącznie w formule wspomagającej, z zachowaniem nadzoru człowieka zgodnie z art. 14 rozporządzenia 2024/1689 (Akt w sprawie sztucznej inteligencji).

### **Słowa kluczowe**

*sztuczna inteligencja, odrzucenie skargi, systemy sztucznej inteligencji, modele sztucznej inteligencji, postępowanie sądowoadministracyjne*

## Abstract

The aim of this study is to assess whether the use of artificial intelligence to verify the grounds for rejecting a complaint under Article 58 of the Law on Proceedings before Administrative Courts may constitute real and legally permissible support for the adjudicatory activities of administrative courts. The study involved the design and implementation of a web-based application built on a language model that analyses the content of administrative complaints and generates a draft court decision along with its justification. The evaluation demonstrated the technical feasibility of algorithmic classification to a limited extent, while also revealing structural barriers resulting from the incompleteness of textual data. The study concludes that the use of AI is permissible only in a supportive capacity, provided that human oversight is ensured in accordance with Article 14 of Regulation 2024/1689 (EU AI Act).

## Keywords

*Artificial intelligence, rejection of the complaint, AI systems, administrative court proceedings*

## Wprowadzenie

Zasadniczym problemem badawczym jest ocena, czy algorytmiczna kwalifikacja przesłanek z art. 58 ustawy z dnia 30.08.2002 r. – Prawo o postępowaniu przed sądami administracyjnymi (cyt. dalej jako „p.p.s.a.”)<sup>1</sup>, może zostać uznana za technicznie wykonalne oraz prawnie dopuszczalne wsparcie działalności orzeczniczej sądu. Odpowiedź na to pytanie wymaga uwzględnienia rzeczywistej architektury badanego narzędzia, jakości i zakresu danych wejściowych i granic informacyjnych samego modelu. Rozważania służą zatem ustaleniu, w jakim zakresie model językowy może wspierać wstępną analizę formalnoprawną skargi, nie naruszając przy tym standardów prawa krajowego i unijnego oraz nadrzędnej roli sędziego w procesie orzekania.

Dla potrzeb opracowania przyjmujemy definicję sztucznej inteligencji (cyt. dalej jako „AI”) z zakresu IT, zgodnie z którą definiuje się ją jako systemy informatyczne zdolne do analizy danych, wnioskowania oraz podejmowania działań ukierunkowanych na realizację określonych celów<sup>2</sup>. W sensie technicznym AI obejmuje algorytmy i modele obliczeniowe umożliwiające generowanie predykcji, rekomendacji lub decyzji na podstawie danych. Rozporządzenie Parlamentu Europejskiego i Rady (UE) 2024/1689 z 13.06.2024 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 (cyt. dalej jako „rozporządzenie 2024/1689”)<sup>3</sup> nie podaje definicji normatywnej AI. Definiuje natomiast pojęcia takie jak „system AI” oraz „model AI ogólnego przeznaczenia”. Zgodnie z art. 3 pkt 1 rozporządzenia 2024/1689 „system AI” oznacza system maszynowy zaprojektowany do działania z różnym poziomem autonomii po jego wdrożeniu, który może wykazywać zdolność adaptacji po jego wdrożeniu oraz – na potrzeby wyraźnych lub dorozumianych celów – wnioskuje, jak generować na podstawie otrzymanych

---

<sup>1</sup> Dz.U. z 2026 r., poz. 143.

<sup>2</sup> F. Kurp, *Sztuczna inteligencja od podstaw*, Gliwice 2023, s. 11-12.

<sup>3</sup> Dz.Urz. UE L z 2024 r., poz. 1689.

danych wejściowych wyniki takie jak predykcje, treści, zalecenia lub decyzje mogące wpływać na środowisko fizyczne lub wirtualne<sup>4</sup>. Zakres definicji obejmuje systemy wspomagające proces podejmowania decyzji przez organy państwa, które są systemami wysokiego ryzyka w rozumieniu art. 6 (i motywu 61) rozporządzenia 2024/1689 oraz załączników – III (pkt 8 lit. a) i VIII (tj. „systemy AI przeznaczone do wykorzystywania przez organ wymiaru sprawiedliwości lub w jego imieniu w celu wspomagania organu wymiaru sprawiedliwości w badaniu i interpretacji stanu faktycznego i przepisów prawa oraz w stosowaniu prawa do konkretnego stanu faktycznego lub do wykorzystywania w podobny sposób w alternatywnych metodach rozwiązywania sporów”). Pojęcia „system AI” nie można utożsamiać z pojęciem „modelu AI”. W literaturze technicznej model AI to konstrukt matematyczny, wykonujący określone zadania, wytrenowany do rozpoznawania wzorów, dokonywania predykcji czy podejmowania decyzji opartych o dane. System AI jest natomiast rozwiązaniem złożonym; obejmuje co najmniej jeden model AI wraz z infrastrukturą danych i wnioskowania oraz komponentami umożliwiającymi korzystanie z systemu (np. interfejsem, API)<sup>5</sup>. Takie rozumienie tego pojęcia potwierdza motyw 97 zd. 6 rozporządzenia 2024/1689.

Na potrzeby opracowania przyjmujemy, że uczenie maszynowe stanowi podobszar AI polegający na budowie modeli zdolnych do klasyfikowania danych na podstawie wzorców wykrytych w zbiorach treningowych (por. motyw 12 rozporządzenia 2024/1689)<sup>6</sup>. Wyróżnia się kilka podstawowych paradygmatów uczenia maszynowego. W pracy zastosowano uczenie nadzorowane, w którym model trenowany jest na zbiorze danych zawierającym zarówno cechy opisujące sprawę, jak i odpowiadające im rozstrzygnięcia<sup>7</sup>. Metoda ta znajduje szczególne zastosowanie w zadaniach klasyfikacyjnych, takich jak przypisanie skardze określonej przesłanki odrzucenia na podstawie art. 58 p.p.s.a. Istotnym elementem uczenia maszynowego jest ocena jakości modelu, dokonywana za pomocą odpowiednich miar statystycznych (dokładność, precyzja, czułość)<sup>8</sup>. Jednak sama wysoka dokładność modelu nie zawsze świadczy o jego użyteczności, zwłaszcza w przypadku danych nie zrównoważonych; ma to szczególne znaczenie w zastosowaniach prawnych, gdzie błędna klasyfikacja może prowadzić do niepożądanych konsekwencji proceduralnych<sup>9</sup>.

---

<sup>4</sup> Zob. m.in.: L. Feiler, B. König, *Komentarz do art. 3 [w:] C. N. Pehlivan, N. Forgó, P. Valcke (red.), The EU's Artificial Intelligence (AI) Act. A Commentary*, Alphen aan den Rijn 2025, s. 57-59.

<sup>5</sup> D. Fernández-Llorca, E. Gómez, I. Sánchez, G. Mazzini, An interdisciplinary account of the terminological choices by EU policymakers ahead of the final agreement on the AI Act: AI system, general purpose AI system, foundation model, and generative AI, „Artificial Intelligence and Law” 2025, vol. 33, s. 877-878.

<sup>6</sup> A. Géron, *Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow*, Gliwice 2023, s. 24-28. Zob. też K. H. Kamińska, M. Cebula, *Wizualizacja plików binarnych i metody uczenia maszynowego w detekcji i klasyfikacji złośliwego oprogramowania*, „Cybersecurity and Law” 2025, nr 2(14), s. 210.

<sup>7</sup> M. Harrison, *Machine Learning Pocket Reference. Working with Structured Data in Python*, Gliwice 2024, s. 22-23 i 93.

<sup>8</sup> *Ibidem*, s. 141.

<sup>9</sup> A. Géron, *op.cit.*, s. 48-49.

## Koncepcja aplikacji wydającej postanowienia

Opracowana aplikacja webowa<sup>10</sup> wykorzystuje model językowy AI, którego zadaniem jest analiza treści skargi administracyjnej, oraz przypisanie jej – na podstawie art. 58 p.p.s.a. – właściwej przesłanki odrzucenia, wraz z wygenerowaniem projektu uzasadnienia postanowienia. Aplikacja działała w oparciu o: (1) przepisy rozporządzenia 2024/1689 oraz akty wykonawcze do niego; (2) przepisy ustawy – Prawo o postępowaniu przed sądami administracyjnymi; (3) zasady wykładni prawa w tym wybrane wnioski prawnicze, (4) rzeczywiste komplety spraw włączając w to: skargi administracyjne (dane syntetyczne) oraz wydane na jej podstawie postanowienie sądu administracyjnego (wraz z uzasadnieniem i pouczeniem) z Centralnej Bazy Orzeczeń Sądów Administracyjnych (cyt. dalej jako „CBOSA”)<sup>11</sup>. Aplikacja została zaprojektowana jako narzędzie badawcze w rozumieniu motywu 21 oraz art. 2 ust. 8 rozporządzenia 2024/1689. Ponieważ Polska jeszcze nie uchwaliła ustawy, określającej obszary wskazane w rozporządzeniu 2024/1689, zatem w opracowaniu nie odniesiono się do rozwiązań przyjętych w projekcie z 5.02.2025 r. ustawy o systemach sztucznej inteligencji<sup>12</sup>. W celu oceny działania aplikacji przyjęto kryteria odnoszące się przede wszystkim do poprawności kwalifikacji procesowej, tj.:

1. poprawność identyfikacji przesłanki odrzucenia – zgodność przypisanej podstawy prawnej z treścią skargi i obowiązującymi przepisami;
2. spójność i adekwatność uzasadnienia – stopień, w jakim wygenerowane uzasadnienie odpowiada wymogom prawnym oraz zasadom logicznym;
3. zdolność do identyfikowania braków formalnych oraz ich prawidłowej klasyfikacji procesowej;
4. zakres koniecznej ingerencji człowieka w celu korekty lub zatwierdzenia rozstrzygnięcia.

Tak ujęta koncepcja aplikacji mieści się w katalogu systemów wspomagania czynności sądowych, które nie mają „znaczącego wpływu na wynik procesu decyzyjnego”, w tym tych, których celem jest „wykonywania wąsko określonego zadania proceduralnego” w rozumieniu art. 6 ust. 3 lit. a rozporządzenia 2024/1689. Należy ją traktować wyłącznie jako instrument wspomagający analizę materiału procesowego, funkcjonujący w modelu *human-in-the-loop*, w którym ostateczna ocena spełnienia przesłanek procesowych oraz podjęcie rozstrzygnięcia pozostają wyłączną kompetencją sędziego<sup>13</sup>.

Backend aplikacji zaimplementowano w środowisku Python z wykorzystaniem bibliotek do trenowania modeli językowych oraz relacyjnej bazy danych tj. PyTorch, Postgres SQL. Warstwę frontendową stworzono przy użyciu frameworku React z Node.js. Dockera użyto do konteneryzacji rozwiązania.

---

<sup>10</sup> Autorami aplikacji są A. Mroczkowska i mgr inż. P. Deptuła. Funkcje koordynacyjne i weryfikacyjne pod względem zgodności z prawem sprawowała A. Skóra.

<sup>11</sup> <https://orzeczenia.nsa.gov.pl/cbo/query> [dostęp: 10.03.2026].

<sup>12</sup> <https://www.gov.pl/web/premier/projekt-ustawy-o-systemach-sztucznej-inteligencji> [dostęp: 10.03.2026 r.].

<sup>13</sup> Zob. m.in. E. Mosqueira-Rey, E. Hernández-Pereira, D. Alonso-Ríos, J. Bobes-Bascarán, Á. Fernández-Leal, *Human-in-the-Loop Machine Learning: A State of the Art*, „Artificial Intelligence Review” 2023, vol. 56(4), s. 3005 i n.; I. Banks, *Judges-in-the-Loop? Judicial Involvement in Human Oversight under the AI Act*, „International Journal of Law and Information Technology” 2026, nr 34, s. 2.

## Przygotowanie danych – *Few-shot learning*, dane syntetyczne

Przygotowanie danych stanowi podstawowy etap projektowania systemów opartych na uczeniu maszynowym, w istotny sposób determinując ich rzetelność i użyteczność<sup>14</sup>. W kontekście zastosowań w wymiarze sprawiedliwości problem ten nabiera znaczenia ze względu na ograniczoną dostępność danych orzeczniczych oraz ich wrażliwy charakter, m.in. związany z obowiązkiem ochrony danych osobowych i ograniczoną jawnością postępowania sądowoadministracyjnego. Z tego względu w opracowaniu zastosowano podejście określane jako *few-shot learning*, polegające na wykorzystaniu niewielkiej liczby reprezentatywnych przykładów w celu dostosowania modelu do konkretnego zadania<sup>15</sup>. Nawet jednak przy ograniczonej liczbie przykładów konieczne jest zachowanie wysokiej jakości danych uczących, które powinny być jednoznaczne, poprawne merytorycznie oraz zgodne z obowiązującym stanem prawnym, gdyż w warunkach niewielkiego zbioru danych każdy błąd może istotnie wpłynąć na działanie modelu<sup>16</sup>.

Uzupełnieniem ograniczonego zbioru danych rzeczywistych były dane syntetyczne, rozumiane jako generowane w sposób kontrolowany skargi, odzwierciedlające typowe przesłanki odrzucenia skargi z art. 58 p.p.s.a. Dane syntetyczne wspierają proces trenowania modeli, pod warunkiem zachowania zgodności z rzeczywistą strukturą danych oraz unikania wprowadzania sztucznych zależności<sup>17</sup>. Zastosowanie danych syntetycznych miało charakter pomocniczy i służyło ograniczeniu ryzyka naruszenia przepisów o ochronie danych osobowych. Nie zastępują one danych rzeczywistych, a tylko wspierają proces weryfikacji.

## Analiza skuteczności modelu językowego i jakości postanowień przez niego wydawanych

Opracowany system analizujący treść skargi i wskazujący potencjalną podstawę jej odrzucenia mieści się w definicji systemu AI w ujęciu przyjętym przez art. 3 pkt 1 rozporządzenia 2024/1689. Jednak motyw 61 rozporządzenia 2024/1689 stanowi, że niektóre systemy przeznaczone na potrzeby sprawowania wymiaru sprawiedliwości i procesów demokratycznych należy zaklasyfikować jako systemy wysokiego ryzyka, biorąc pod uwagę ich potencjalnie istotny wpływ m.in. na demokrację, praworządność, wolności osobiste, a także prawo do skutecznego środka prawnego i dostępu do bezstronnego sądu<sup>18</sup>. Dlatego wykorzystanie modelu językowego w związku z art. 58 p.p.s.a. wymaga zachowania podwyższonych standardów transparentności, kontroli i odpowiedzialności właściwych dla tego rodzaju systemów.

Artykuł 14 rozporządzenia 2024/1689 wprowadza obowiązek zapewnienia odpowiedniego nadzoru człowieka, natomiast art. 26 określa najważniejsze obowiązki podmiotów stosujących systemy AI wysokiego ryzyka. Zatem jeśli nawet model generuje projekt postanowienia o odrzuceniu skargi, odpowiedzialność za jego treść i skutki procesowe spoczywa na sędzim jako

---

<sup>14</sup> M. Harrison, *op.cit.*, s. 19, 24-25, 32-34.

<sup>15</sup> E. Mosqueira-Rey, E. Hernández-Pereira, D. Alonso-Ríos, J. Bobes-Bascarán, Á. Fernández-Leal, *op.cit.*, s. 3011.

<sup>16</sup> M. Harrison, *op.cit.*, s. 24-25.

<sup>17</sup> *Ibidem*, s. 90-91.

<sup>18</sup> Podobnie m.in. I. Banks, *op.cit.*, s. 2.

podmiocie stosującym w świetle art. 3 pkt 4 i art. 26 rozporządzenia 2024/1689<sup>19</sup>. Celem nadzoru ludzkiego jest „zapobieganie ryzyku dla zdrowia, bezpieczeństwa lub praw podstawowych lub minimalizowanie takiego ryzyka, które może się pojawić, gdy system AI wysokiego ryzyka jest wykorzystywany zgodnie z jego przeznaczeniem lub w warunkach dającego się racjonalnie przewidzieć niewłaściwego wykorzystania” – w szczególności tych ryzyk, które utrzymują się pomimo zastosowania pozostałych wymogów rozporządzenia dotyczących systemów wysokiego ryzyka. Prawdopodobne jest jednak, że wiele systemów wspomagania czynności sądowych zostanie wyłączonych z klasyfikacji „wysokiego ryzyka”. Artykuł 6 ust. 3 *in fine* rozporządzenia 2024/1689 przewiduje bowiem wyjątek dla systemów AI, które nie mają „znaczącego wpływu na wynik procesu decyzyjnego”, w tym tych, których celem jest „wykonywania wąsko określonego zadania proceduralnego” (art. 6 ust. 3 lit.a rozporządzenia 2024/1689), „poprawienia wyniku zakończonej uprzednio czynności wykonywanej przez człowieka” (art. 6 ust. 3 lit.b rozporządzenia 2024/1689), „wykrywania wzorców podejmowania decyzji lub odstępstw od wzorców podjętych uprzednio decyzji i nie ma na celu zastąpienia ani wywarcia wpływu na zakończoną uprzednio ocenę dokonaną przez człowieka – bez odpowiedniej weryfikacji przez człowieka” lub „wykonywanie zadań przygotowawczych w kontekście oceny istotnej z punktu widzenia przypadków wykorzystania wymienionych w załączniku III” (art. 6 ust. 3 lit.c i lit.d rozporządzenia 2024/1689).

W świetle art. 58 p.p.s.a. postanowienie jest aktem władczym sądu administracyjnego, wywołującym określone skutki procesowe dla strony i zamykającym drogę merytorycznego rozpoznania sprawy, który z zasady nie rozstrzyga o istocie sprawy<sup>20</sup>. Z tego względu całkowita automatyzacja takiego rozstrzygnięcia byłaby trudna do pogodzenia także z zasadą prawa do sądu oraz wymogiem indywidualnego rozpoznania sprawy. Jednakże, jeżeli model językowy pełni funkcję analityczną, tj. porządkującą dane, wskazującą możliwe przesłanki odrzucenia skargi oraz wspierającą sporządzenie projektu uzasadnienia może stanowić narzędzie zwiększające efektywność pracy sądu. Zasadnicze znaczenie ma zatem rozróżnienie między automatyzacją czynności pomocniczych a zastąpieniem – działaniem AI – wydania aktu jurysdykcyjnego.

### Analiza etyczna problemu

Rozwój AI w obszarze wymiaru sprawiedliwości rodzi m.in. problemy o charakterze aksjologicznym, które powinny być uwzględniane już na etapie projektowania i wdrażania takich narzędzi<sup>21</sup>.

---

<sup>19</sup> D. Ashkar, Ch. Schröder, *Das Gesetz über künstliche Intelligenz der Europäischen Union (KI Verordnung)*, „Betriebs-Berater” 2024, nr 15, s. 776; J. Wendt, D. H. Wendt, *Das neue Recht der Künstlichen Intelligenz Artificial Intelligence Act (AI Act)*, Baden Baden 2024, s. 76-77; L. Feiler, B. König, *op.cit.*, s. 61.

<sup>20</sup> M. Jagielska, J. Jagielski, R. Stankiewicz, M. Grzywacz, *Komentarz do art. 160 [w:] R. Hauser, M. Wierzbowski, R. Stankiewicz (red.), Prawo o postępowaniu przed sądami administracyjnymi. Komentarz*, Warszawa 2025, Legalis/el.; B. Dauter, *Komentarz do art. 160 [w:] B. Dauter, A. Kabat, M. Niezgódka-Medek (red.), Prawo o postępowaniu przed sądami administracyjnymi. Komentarz*, Warszawa 2024, Lex/el.

<sup>21</sup> A. M. John, M. U. Aiswarya, J. T. Panachakel, *Ethical Challenges of Using Artificial Intelligence in Judiciary*, arXiv:2504.19284, Cornell University 2025, <https://arxiv.org/abs/2504.19284> [dostęp: 10.03.2026]. Zob. szerzej: P. Van Eecke, B. Regenhardt, *Komentarz do art. 1 [w:] C.N. Pehlivan, N. Forgó, P. Valcke (red.), The EU's Artificial Intelligence (AI) Act. A Commentary*, Alphen aan den Rijn 2025, s. 11-12

Rozporządzenie 2024/1689 w art. 1 *expressis verbis* odwołuje się do koncepcji „godnej zaufania” AI, której fundamentem jest poszanowanie praw podstawowych zapisanych w Karcie praw podstawowych UE<sup>22</sup> oraz zapewnienie wysokiego poziomu ochrony interesów publicznych w dziedzinie zdrowia i bezpieczeństwa (art. 1 oraz motyw 1 rozporządzenia 2024/1689)<sup>23</sup>. W motywie 61 zaznaczono szczególną wrażliwość zastosowań AI w wymiarze sprawiedliwości. Motyw 7 wprost odwołuje się do Europejskiej deklaracji praw i zasad cyfrowych na rzecz cyfrowej dekady<sup>24</sup> oraz Wytycznych w zakresie etyki dotyczące godnej zaufania AI grupy ekspertów wysokiego szczebla ds. AI (cyt. dalej jako „Wytyczne HLEG”)<sup>25</sup>, które pełnią funkcję pomocniczego punktu odniesienia przy wykładni przepisów prawa UE dotyczących technologii cyfrowych w zakresie systemów AI wysokiego ryzyka.

Istotnym zagadnieniem etycznym jest również ryzyko stronniczości algorytmicznej. Systemy uczą się na podstawie danych historycznych, mogących zawierać utrwalone schematy interpretacyjne lub błędy. Problem ten może prowadzić do reprodukcji nierówności w sposób trudny do zauważenia<sup>26</sup>. W kontekście postępowań sędziowsko-administracyjnych ryzyko to mogłoby przejawiać się np. w nadmiernym przypisywaniu określonych przesłanek odrzucenia w sytuacjach granicznych lub niejednoznacznych.

Z uwagi na etyczne aspekty korzystania z systemów AI należy się pochylić także nad przejrzystością działania takich systemów. Mechanizmy funkcjonowania zaawansowanych modeli mogą być trudne do pełnego zrozumienia, co utrudnia ustalenie, na jakiej podstawie sformułowano określony wynik lub rekomendację. Wytyczne HLEG podkreślają znaczenie wyjaśnialności jako warunku budowania zaufania do systemów AI<sup>27</sup>. W postępowaniu sędziowsko-administracyjnym przejrzystość ma szczególne znaczenie ze względu na konieczność sporządzenia uzasadnienia rozstrzygnięcia oraz możliwość jego kontroli instancyjnej. Jeżeli mechanizm działania modelu byłby całkowicie nieczytelny, mogłoby to podważać zaufanie do procesu orzekania.

Ważny jest też aspekt ochrony danych osobowych. Modele te operujące na treści skarg przetwarzają dane, które mogą mieć charakter wrażliwy. Z tego względu ich wykorzystanie musi uwzględniać standardy ochrony prywatności oraz zasadę minimalizacji danych, o której mowa w rozporządzeniu 2016/679 (RODO) i ustawie z dnia 10 maja 2018 r. o ochronie danych osobowych<sup>28</sup>.

---

<sup>22</sup> Zob. m.in. P. Van Eecke, B. Regenhardt, *op.cit.*, s. 15-18; Ch. Wendehorst, *Komentarz do art. 1 [w:] M. Martini, Ch Wendehorst (red.), KI-VO: Verordnung über Künstliche Intelligenz. Kommentar*, München 2024, s. 79.

<sup>23</sup> Zob. m.in. M. Kaczmarczyk, *O systemach sztucznej inteligencji w kontekście praw człowieka w orzecznictwie Europejskiego Trybunału Praw Człowieka*, „Studia Prawa Publicznego” 2025, nr 2(50), s. 20.

<sup>24</sup> Dz.U. UE C 23 z 23.01.2023, s. 1–7. Deklaracja ta jest aktem *soft law* przyjętym wspólnie przez Parlament Europejski, Radę Unii Europejskiej oraz Komisję Europejską w dniu 15.12.2022 r. Zob. też Ch. Wendehorst, *op.cit.*, s. 78-79.

<sup>25</sup> Ethics Guidelines for Trustworthy AI, opracowane przez High-Level Expert Group on Artificial Intelligence powołaną przez Komisję Europejską, 8.04.2019, dostęp: <https://digital-strategy.ec.europa.eu/en/library/ethics-guidelines-trustworthy-ai> [dostęp: 10.03.2026].

<sup>26</sup> P. Kosiak, *Etyczne aspekty rozwoju i wykorzystywania sztucznej inteligencji*, Warszawa 2023, s. 5.

<sup>27</sup> Por. Wytyczne HLEG. Zob. m.in. D. Lubasz, *Przejrzystość i wyjaśnialność sztucznej inteligencji i ich funkcje w RODO i AI Act*, „Monitor Prawniczy” 2024, nr 11, s. 1-2.

<sup>28</sup> Zob. szerzej D. Lubasz, A. Szkurłat, *Relacja aktu o sztucznej inteligencji i ogólnego rozporządzenia o ochronie danych*, „Monitor Prawniczy” 2022, nr 21, s. 1; K. Kaczmarek, M. Karpiuk, C. Melchior, *A Holistic Approach to Cybersecurity and Data Protection in the Age of Artificial Intelligence and Big Data*, „Prawo i więź” 2024, nr 3/(50), s. 104 i n.

Etyczna analiza wykorzystania modelu językowego w stosowaniu art. 58 p.p.s.a. prowadzi do wniosku, że jego zastosowanie może być uznane za dopuszczalne wyłącznie wówczas, gdy spełnione są określone warunki: zachowany zostaje nadzór sędziego jako podmiotu stosującego nad procesem decyzyjnym, ograniczone jest ryzyko stronniczości, zapewniona zostaje przejrzystość działania systemu oraz respektowane są standardy ochrony danych.

## **Opis budowy i funkcji aplikacji stworzonej na potrzeby artykułu**

Architektura aplikacji stworzonej na potrzeby niniejszego opracowania obejmowała warstwę przechowywania danych, warstwę przetwarzania oraz moduł modelu językowego odpowiedzialnego za klasyfikację i generowanie projektu uzasadnienia. Celem aplikacji była weryfikacja, czy algorytmiczna analiza przesłanek formalnoprawnych może zostać uznana za technicznie wykonalną oraz potencjalnie użyteczną w praktyce sądownoadministracyjnej.

### **Dane**

Istotnym problemem badawczym okazała się ograniczona dostępność kompletnych danych orzeczniczych. Z uwagi na ograniczoną jawność postępowania sądownoadministracyjnego zastosowano rozwiązanie polegające na wykorzystaniu danych syntetycznych generowanych na podstawie publicznie dostępnych postanowień sądów oraz rekonstrukcji typowych stanów faktycznych. Pozwoliło to na stworzenie zbioru uczącego obejmujące punkty 1-6 z art. 58 § 1 p.p.s.a., przy jednoczesnym ograniczeniu ryzyka naruszenia poufności danych.

W toku prac monitorowano rozkład poszczególnych kategorii odrzucenia skargi, ponieważ model trenowany na danych zdominowanych przez jedną kategorię ma tendencję do faworyzowania klas liczniejszych, co obniża skuteczność rozpoznawania klas rzadkich.

### **Przetwarzanie danych**

W procesie przygotowania danych zastosowano mechanizmy wstępnego przetwarzania polegające na anonimizacji danych identyfikujących oraz eliminacji elementów niemających znaczenia dla kwalifikacji procesowej. Celem było zarówno ograniczenie „szumu” informacyjnego, jak i minimalizacja przetwarzania danych wrażliwych.

Działania te mają znaczenie nie tylko techniczne, lecz także prawne, ponieważ pozostają w zgodzie z zasadą minimalizacji danych oraz wymogami ochrony prywatności

### **Trenowanie modelu**

Model językowy został wytrenowany w środowisku umożliwiającym przetwarzanie dużych zbiorów tekstu i dostosowanie parametrów klasyfikacji do specyfiki zadania. Proces treningu obejmował podział danych na zbiory uczące i testowe w celu oceny zdolności modelu do uogólniania wyników.

Szczegóły infrastrukturalne (sprzętowe i programistyczne) mają charakter pomocniczy i nie wpływają na zasadnicze wnioski prawne wynikające z przeprowadzonych badań.

### **Wybór głównego modelu**

W literaturze oraz repozytoriach publicznych dostępnych jest wiele modeli embeddingowych dla języka polskiego. Na potrzeby niniejszego badania przeanalizowano kilka modeli językowych przeznaczonych do przetwarzania

języka polskiego. W tym: st-polish-paraphrase-from-distilroberta, sdadas/ mmlw-roberta-large, PKOBP/polish-roberta-8k - różniących się rozmiarem, zakresem kontekstu oraz wymaganiami obliczeniowymi. Zamiast ograniczyć aplikację do jednego rozwiązania, zaimplementowano mechanizm umożliwiający wybór modelu generującego odpowiedź. Pozwoliło to na porównanie jakości klasyfikacji oraz ocenę wpływu parametrów modelu na skuteczność identyfikacji przesłanek z art. 58 p.p.s.a. oraz weryfikację, czy uzyskiwane rezultaty są efektem konkretnej architektury modelu, czy też wynikają z samej możliwości algorytmicznej kwalifikacji przesłanek formalnoprawnych. Wybrany za pomocą mechanizmu model zostawał poddawany dalszemu dostrojeniu na zbiorze danych przygotowanym w ramach projektu.

### **Metoda treningu**

W procesie trenowania zastosowano metodę umożliwiającą skuteczne uczenie przy ograniczonej liczbie danych (SetFit), co było istotne z uwagi na specyfikę materiału orzeczniczego. Proces obejmował dwa etapy: wytworzenie reprezentacji tekstu oraz trenowanie klasyfikatora przypisującego dokument do odpowiedniej kategorii przesłanki z art. 58 p.p.s.a.

### **Proces treningu**

Jak wspomniano wyżej, dane zostały podzielone na zbiory uczące i testowe w celu oceny zdolności modelu do prawidłowej generalizacji. W trakcie treningu monitorowano jakość uzyskiwanych wyników oraz dobierano parametry w sposób pozwalając uniknąć przeuczenia modelu. Trzeba podkreślić, że szczegóły techniczne infrastruktury oraz parametrów obliczeniowych mają charakter pomocniczy i nie wpływają zasadniczo na wnioski wynikające z przeprowadzonych badań.

### **Ewaluacja modelu**

Ocena skuteczności modelu została przeprowadzona zgodnie z wcześniejszą koncepcją procesu treningu, umożliwiło to zweryfikowanie, czy nie dochodzi do nadmiernego dopasowania do danych treningowych.

**Tabela 1.** Rozkład klas w zbiorze w oparciu o model sdadas/mmlw-roberta-large ze wsparciem danych syntetycznych.

<b>Przesłanka</b>	<b>Liczba przypadków</b>	<b>Udział procentowy</b>
Pkt_1	58	19,1%
pkt_2	42	13,8%
pkt_3	43	14,1%
pkt_4	46	15,1%
pkt_5	36	11,8%
pkt_5a	30	9,9%
pkt_6	49	16,1%

**Źródło:** opracowanie własne.

Rozkład klas był względnie wyrównany, co pozwalało ograniczyć ryzyko systematycznego faworyzowania jednej z przesłanek odrzucenia skargi. Model

osiągnął trafność klasyfikacji na poziomie około 90% w odniesieniu do danych treningowych, natomiast na zbiorze testowym osiąga dokładność (*accuracy*) na poziomie około 50%. Różnica ta wskazuje na ograniczoną zdolność generalizacji modelu oraz sugeruje, że sama treść skargi nie zawsze zawiera wystarczający sygnał normatywny do jednoznacznego przypisania właściwej przesłanki z art. 58 p.p.s.a.

**Tabela 2. Porównanie skuteczności modeli (zbiór testowy)**

Model	Accuracy	Kluczowe cechy i ograniczenia
sdadas/mmlw-roberta-large	ok. 50%	Wysoki stopień dopasowania do danych treningowych (90% Acc). Niska zdolność uogólniania
st-polish-paraphrase-from-distilroberta	< 50%	Model referencyjny. Szybszy trening kosztem głębi semantycznej wnioskowania
PKOBP/polish-roberta-8k	ok. 50%	Najwyższy potencjał analizy pełnych skarg. Bardzo wysoki koszt obliczeniowy i obciążenie VRAM
OpenAI-20B	ok. 21%	Silny bias systematyczny (nadużywanie kat. pkt_6). Brak głębokiego rozumienia polskiego prawa
Llama 3.3 70B Versatile	ok. 43%	Znacznie lepsza sprawność semantyczna i prawnicza. Ograniczony przez limity API i politykę tokenów

**Źródło:** opracowanie własne.

Zestawienie wyników wskazuje, że ograniczenia skuteczności nie wynikają wyłącznie z wyboru konkretnej architektury modelu, lecz mają charakter strukturalny i są związane z profilem informacyjnym przesłanek z art. 58 p.p.s.a.

**Tabela 3. Przesłanki służące do klasyfikacji skarg**

Pkt	Co sąd orzeka	Czy widać w skardze?
pkt_1	„to nie jest sprawa sądowoadministracyjna”	może - jeśli przedmiot jest ewidentnie cywilny
pkt_2	„złożono po terminie”	tylko jeśli daty w treści wskazują opóźnienie
pkt_3	„brak podpisu/załączników”	nie - braki formalne widać z akt, nie z treści
pkt_4	„ta sprawa już była rozpatrzona”	może - jeśli skarżący sam wspomina wcześniejsze postępowanie
pkt_5	„spółka nie ma organu”	słabo - może nazwa podmiotu
pkt_5a	„nie ma naruszenia interesu prawnego”	może - jeśli widać brak związku prawnego
pkt_6	„z innych przyczyn”	to <i>sui generis</i> „worek na wszystko”

**Źródło:** opracowanie własne.

Powyższe zestawienie pokazuje, że część przesłanek ma charakter językowo uchwytny, podczas gdy inne zależą od danych procesowych ujawnianych dopiero w aktach sprawy. Ograniczenia skuteczności modelu nie wynikają więc wyłącznie z niedoskonałości algorytmicznej, lecz z niepełności danych wejściowych. Wyniki ewaluacji wskazują, że AI może wspierać wstępną analizę formalnoprawną skarg, jednak nie ma możliwości, aby wykluczyć pierwiastek ludzki przy kwalifikacji przesłanek wymagających przeanalizowania akt sprawy. Tym samym algorytmiczna klasyfikacja art. 58 p.p.s.a. jest technicznie wykonalna **w ograniczonym zakresie**.

## Inne metody nauki

W celu weryfikacji czy ograniczenia uzyskanych wyników mają charakter wyłącznie techniczny, przeprowadzono również testy z wykorzystaniem modeli językowych ogólnego przeznaczenia w rozumieniu art. 3 pkt 63 rozporządzenia 2024/1689, zdolnych do generowania odpowiedzi na podstawie dostarczonego kontekstu normatywnego. Modele te otrzymywały treść skargi wraz z definicją art. 58 p.p.s.a. oraz poleceniem przypisania właściwej przesłanki odrzucenia. Uzyskane rezultaty nie wykazały istotnej poprawy skuteczności klasyfikacji. W szczególności zaobserwowano tendencję do nadmiernego stosowania najbardziej ogólnej kategorii z art. 58 § 1 pkt 6 p.p.s.a., co prowadziło do obniżenia precyzji rozstrzygnięć.

Porównywanie wyników (Tabela 2) wskazuje, że ograniczenia skuteczności nie wynikają wyłącznie z zastosowanej architektury modelu, lecz mają charakter strukturalny. Wynikają one z faktu, że część przesłanek z art. 58 p.p.s.a. opiera się na danych zawartych jedynie w aktach sprawy (np. wezwania do uzupełnienia braków formalnych), które nie są dostępne wyłącznie na podstawie treści skargi. Na gruncie obecnego stanu wiedzy, nawet zaawansowane modele językowe nie są w stanie w sposób stabilny dokonywać autonomicznej kwalifikacji wszystkich przesłanek odrzucenia skargi. Jednocześnie wyniki te potwierdzają, że w zakresie przesłanek semantycznie uchwytnych w tekście możliwe jest częściowe wsparcie analityczne.

Tym samym analiza alternatywnych podejść modelowych wzmacnia zasadniczy wniosek niniejszego opracowania. Zastosowanie tego rodzaju narzędzi powinno odbywać się przy zachowaniu nadzoru sprawowanego poprzez osoby fizyczne, zgodnie z wymogami wynikającymi z rozporządzenia 2024/1689, w szczególności art. 14, oraz z uwzględnieniem zasad ogólnych postępowania sądownoadministracyjnego.

## Trudności w implementacji aplikacji

Największe trudności napotkane w toku implementacji aplikacji nie miały charakteru wyłącznie technicznego tylko metodologiczny. Podstawowym problemem okazało się precyzyjne określenie celu modelu: czy ma on odtwarzać schemat rozumowania sądu, czy jedynie klasyfikować treść skargi według przesłanek z art. 58 p.p.s.a. Praktyka pokazała, że część przesłanek odrzucenia skargi opiera się na informacjach zawartych w aktach sprawy, które nie są dostępne wyłącznie na podstawie treści skargi. W konsekwencji model operujący wyłącznie na tekście pisma procesowego funkcjonuje w warunkach niepełności informacyjnej. Drugą istotną trudnością było ustalenie kryteriów oceny „poprawności” rozstrzygnięcia. W prawie poprawność nie ma wyłącznie

charakteru statystycznego, lecz wiąże się z prawidłową subsumcją normy prawnej do ustalonego stanu faktycznego. Zatem nawet wysoka skuteczność klasyfikacyjna nie przesądza o prawnej trafności modelu.

Powyższe trudności wskazują, że zastosowanie modelu językowego w analizie art. 58 p.p.s.a. może być realne jedynie w zakresie czynności pomocniczych, w szczególności wstępnej kwalifikacji formalnoprawnej. Implementacja potwierdziła techniczną wykonalność algorytmicznej klasyfikacji części przesłanek, jednocześnie ujawniając granice automatyzacji wynikające ze specyfiki postępowania.

## **Faza implementacyjna aplikacji wraz z wyjaśnieniem podstawowych pojęć uczenia maszynowego**

Modele językowe wykorzystywane w niniejszym badaniu wymagają przekształcenia tekstu do postaci numerycznej reprezentacji, umożliwiającej jego dalszą analizę algorytmiczną. Reprezentacja wektorowa pozwala odwzorować relacje semantyczne między fragmentami tekstu poprzez ich położenie w przestrzeni liczbowej, co stanowi podstawę współczesnych metod przetwarzania języka naturalnego<sup>29</sup>. W rozwiązaniach typu Sentence-BERT *embedding* odnosi się do całych fragmentów tekstu, co umożliwia porównywanie dokumentów pod względem znaczeniowym<sup>30</sup>.

W zastosowanym modelu treść skargi administracyjnej była przekształcana w reprezentację liczbową, stanowiącą podstawę dalszej kwalifikacji do jednej z przesłanek z art. 58 § 1 p.p.s.a. *Embedding* nie stanowi jednak „wiedzy o sprawie” w sensie procesowym, lecz jedynie formalną reprezentację treści zawartej w tekście. Model operuje wyłącznie na danych wejściowych, które zostały mu przekazane, i nie kompensuje braków informacyjnych wynikających z niepełności materiału<sup>31</sup>.

Część przesłanek z art. 58 p.p.s.a. może być uchwytana na poziomie językowym (np. niedopuszczalność drogi sądowej czy brak interesu prawnego), inne natomiast wymagają ustaleń dotyczących przebiegu postępowania – w szczególności czynności sądu i stron, takich jak doręczenia, wezwania do usunięcia braków formalnych czy weryfikacja tożsamości sprawy. Informacje te znajdują się w aktach sprawy i nie zawsze są reprezentowane w samej treści skargi. Oznacza to, że *embedding* stanowi jednocześnie warunek technicznej wykonalności automatycznej klasyfikacji oraz jej granicę. Model może identyfikować powtarzalne wzorce językowe charakterystyczne dla określonych kategorii odrzucenia, jednak nie jest w stanie ustalić faktów procesowych, które nie zostały ujawnione w tekście. W literaturze podkreśla się, że skuteczność modelu zależy wprost od jakości i kompletności danych wejściowych<sup>32</sup>. W sytuacji, gdy część przesłanek opiera się na danych pozatekstowych, klasyfikacja ma charakter cząstkowy i opiera się na sygnałach pośrednich.

Uzyskana w badaniu rozbieżność pomiędzy skutecznością na danych treningowych a walidacyjnych należy interpretować właśnie w tym kontekście – jako przejaw granicy informacyjnej automatyzacji, a nie wyłącznie

---

<sup>29</sup> T. Mikolov T., K. Chen, G. Corrado, J. Dean, *Efficient Estimation of Word Representations in Vector Space*, arXiv:1301.3781, 2013, <https://arxiv.org/abs/1301.3781> [dostęp: 21.02.2026].

<sup>30</sup> N. Reimers N., I. Gurevych I., *Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks*, arXiv:1908.10084, 2019, <https://arxiv.org/abs/1908.10084> [dostęp: 21.02.2026].

<sup>31</sup> *Ibidem*.

<sup>32</sup> *Ibidem*.

niedoskonałości technicznej modelu. Algorytmiczna kwalifikacja przesłanek z art. 58 p.p.s.a. jest zatem technicznie możliwa w zakresie, w jakim przesłanki są uchwytne w warstwie językowej skargi. W odniesieniu do przesłanek wymagających ustaleń wynikających z akt sprawy niezbędne pozostaje włączenie danych procesowych oraz zachowanie decyzyjnej roli sędziego.

## Ograniczenie „kontekstu normatywnego” w modelu AI, geneza ~50% accuracy

W badaniu przyjęto założenie, że model językowy, działając w oparciu o przyjęte założenia, będzie w stanie przypisać właściwą przesłankę odrzucenia skargi na podstawie jej treści. Analiza empiryczna wykazała jednak, że w części przypadków sygnał decyzyjny nie znajduje się w tekście skargi, lecz w danych procesowych ujawnionych dopiero w aktach sprawy.

Z perspektywy dogmatycznej art. 58 p.p.s.a. stanowi samodzielną normę procesową określającą przesłanki odrzucenia skargi. Jednak jego zastosowanie wymaga ustalenia określonych faktów procesowych. Jeżeli fakty te nie są reprezentowane w danych wejściowych modelu, klasyfikacja ma charakter cząstkowy i opiera się na sygnałach pośrednich.

Uzyskany wynik walidacyjny na poziomie ok. 50% accuracy należy zatem interpretować przede wszystkim jako wskaźnik niepełności danych wejściowych, a nie wyłącznie niedoskonałości technicznej modelu. Model operujący wyłącznie na tekście skargi funkcjonuje w warunkach ograniczonego dostępu do informacji procesowych, które w praktyce warunkują część rozstrzygnięć formalnych.

Artykuł 58 § 1 p.p.s.a. obejmuje przesłanki o zróżnicowanym „profilu informacyjnym”. Część z nich może być uchwytne w warstwie językowej skargi, inne natomiast zależą od danych wynikających z przebiegu postępowania (doręczeń, wezwań, rejestrów spraw, statusu reprezentacji).

Tabela 2. Granice merytoryczne analizy skarg

Typ informacji decyzyjnej	Art. 58 ppsa	Dlaczego „sam tekst skargi” bywa niewystarczający	Konsekwencja dla modelu
Sygnał głównie semantyczny (opis przedmiotu/relacji prawnej)	Pkt 1, pkt 5a, część pkt 6	Skarga zawiera opis przedmiotu i zarzuty; bywa możliwe uchwycenie „niedopuszczalności” na poziomie języka	Realna szansa sensownej klasyfikacji na embeddingach
Sygnał oparty o metadane czasowe	Pkt 2	Wymaga daty wniesienia i doręczenia; w skardze bywa niepełne lub niespójne	Wysokie ryzyko błędów bez metadanych z akt/ systemu
Sygnał proceduralny (wezwanie, termin, brak reakcji)	Pkt 3	Warunek „nie uzupełniono w terminie” dotyczy przebiegu czynności sądu i doręczeń, nie samej narracji skargi	Bez akt – w modelu występuje luka informacyjna
Sygnał systemowy	Pkt 4	Wymaga porównania z innymi sprawami (rejestr	Konieczna integracja z rejestrem/

(sprawa w toku/ <i>res iudicata</i> )		spraw); skarga rzadko daje kompletny obraz	wyszukiwaniem spraw
Sygnal rejestrowo – reprezentacyjny	Pkt 5	Wymaga danych o zdolności sądowej/procesowej, umocowaniu, organach; część informacji znajdująca się poza kontekstem	Potrzebne dane z rejestrów + kontrola formalna

**Źródło:** opracowanie własne.

Powyższe zestawienie wskazuje, że ograniczenia skuteczności modelu mają charakter strukturalny. W zakresie, w jakim przesłanki z art. 58 p.p.s.a. są uchwytnie w warstwie językowej skargi, możliwe jest częściowe wsparcie algorytmiczne. W odniesieniu do przesłanek zależnych od czynności procesowych i danych aktowych niezbędne pozostaje włączenie informacji pozatekstowych oraz zachowanie decyzyjnej roli sędziego. Otrzymany wynik należy zatem traktować jako empiryczne potwierdzenie granicy informacyjnej automatyzacji, a nie jako dowód braku przydatności narzędzia. Algorytmiczna kwalifikacja przesłanek z art. 58 p.p.s.a. jest technicznie możliwa w ograniczonym zakresie. W konsekwencji ponownie możemy stwierdzić, że aplikacja może stanowić wsparcie w wstępnej analizie formalnoprawnej skarg, jednak nie zastępuje subsumcji dokonywanej w ramach postępowania sądowoadministracyjnego.

## **Granice merytoryczne analizy skarg w modelu zbudowanym na potrzeby pracy**

Granice zastosowanego modelu wynikają nie tyle z samej metody uczenia, ile z definicji danych wejściowych. Model przetwarza treść skargi i przypisuje ją do jednej z przesłanek z art. 58 p.p.s.a., operując wyłącznie na materiale językowym strony. Oznacza to, że funkcjonuje on w oparciu o „świadectwo językowe” uczestnika postępowania, a nie o pełny materiał procesowy. W takim ujęciu model może:

- wskazać prawdopodobną podstawę odrzucenia, gdy jest ona silnie powiązana z treścią skargi (np. niedopuszczalność drogi sądowoadministracyjnej),
  - uporządkować materiał argumentacyjny,
  - wygenerować roboczy projekt uzasadnienia o charakterze pomocniczym. Model nie jest natomiast w stanie w sposób weryfikowalny:
  - ustalić zachowania terminów bez danych o doręczeniach (art. 58 § 1 pkt 2 p.p.s.a.),
  - stwierdzić niezuzupełnienia braków formalnych po wezwaniu (art. 58 § 1 pkt 3 p.p.s.a.),
  - zweryfikować tożsamości sprawy w toku lub prawomocnie osądzonej (art. 58 § 1 pkt 4 p.p.s.a.),
  - potwierdzić zdolności sądowej lub prawidłowej reprezentacji (art. 58 § 1 pkt 5 p.p.s.a.)
- jeżeli informacje te nie są obecne w samym tekście skargi.

Granica ta ma znaczenie nie tylko techniczne, lecz przede wszystkim prawne. Postanowienie wydane na podstawie art. 58 p.p.s.a. ma charakter władczy i wywołuje określone skutki procesowe dla strony. Zastosowanie normy

wymaga prawidłowej subsumcji ustalonego stanu faktycznego pod przepis prawa. Jeżeli stan faktyczny nie jest w pełni reprezentowany w danych wejściowych modelu, jego kwalifikacja ma charakter częściowy.

## Podsumowanie

Wyniki przeprowadzonej ewaluacji potwierdziły techniczną wykonalność algorytmicznej klasyfikacji w ograniczonym zakresie. Model osiągnął wysoką skuteczność na danych treningowych, jednak istotny spadek dokładności na zbiorze testowym ujawnił strukturalne ograniczenia wynikające z niepełności danych wejściowych. Analiza wykazała, że część przesłanek z art. 58 p.p.s.a. ma charakter językowo uchwytny i może być identyfikowana na podstawie samej treści skargi, natomiast inne wymagają ustaleń wynikających z akt sprawy. Granica skuteczności modelu nie wynika zatem z jego niedoskonałości, lecz z ograniczonego zakresu informacji dostępnych w analizowanym materiale.

Zastosowanie tego rodzaju systemu AI jako systemu wysokiego ryzyka dodatkowo wymaga zapewnienia nadzoru człowieka, przejrzystości działania oraz rozdzielenia rekomendacji systemu od ostatecznego rozstrzygnięcia sądu. Badanie wykazało, że najbardziej obiecującym kierunkiem dalszego rozwoju jest model hybrydowy, łączący analizę językową z wykorzystaniem danych z akt sprawy tam, gdzie prawo operuje jednoznacznymi warunkami formalnymi. Takie podejście może ograniczyć lukę informacyjną i zwiększyć skuteczność klasyfikacji przy jednoczesnym zachowaniu przejrzystości systemu.

Wykorzystanie AI do weryfikowania przesłanek z art. 58 p.p.s.a. jest więc technicznie możliwe i potencjalnie użyteczne, jednak wyłącznie w formule wspomagającej. Model językowy może stanowić narzędzie porządkujące materiał sprawy, wspierające wstępną analizę formalnoprawną oraz generujące projekt uzasadnienia, lecz – w świetle obowiązującego prawa – nie zastępuje subsumcji dokonywanej przez sąd ani indywidualnej oceny stanu faktycznego. Tym samym zastosowanie AI może być skuteczne pod warunkiem zachowania nadrzędnej roli sędziego, zapewnienia transparentności oraz respektowania standardów wynikających z prawa krajowego i unijnego.

## Bibliografia

- Ashkar D., Schröder Ch., *Das Gesetz über künstliche Intelligenz der Europäischen Union (KI Verordnung)*, „Betriebs-Berater” 2024, nr 15.
- Banks I., *Judges-in-the-Loop? Judicial Involvement in Human Oversight under the AI Act*, „International Journal of Law and Information Technology” 2026, nr 34.
- Chojnowski M., *Etyka sztucznej inteligencji – wprowadzenie*, Centrum Etyki Technologii Instytutu Humanites, Warszawa 2022.
- Dauter B., Kabat A., Niezgódka-Medek M., *Prawo o postępowaniu przed sądami administracyjnymi. Komentarz*, Warszawa 2024.
- Fernández-Llorca D., Gómez E., Sánchez I., Mazzini G., *An interdisciplinary account of the terminological choices by EU policymakers ahead of the final agreement on the AI Act: AI system, general purpose AI system, foundation model, and generative AI*, „Artificial Intelligence and Law” 2025, vol. 33.
- Géron A., *Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow*, Gliwice 2023.
- Harrison M., *Machine Learning Pocket Reference. Working with Structured Data in Python*, Gliwice 2024.
- Jagielska M., Wiktorowska A., Wajda P. [w:] R. Hauser, M. Wierzbowski, R. Stankiewicz (red.), *Prawo o postępowaniu przed sądami administracyjnymi. Komentarz*, Warszawa 2025.

- John A. M., Aiswarya M. U., Panachakel J. T., *Ethical Challenges of Using Artificial Intelligence in Judiciary*, arXiv:2504.19284, Cornell University 2025, <https://arxiv.org/abs/2504.19284> [dostęp: 10.03.2025].
- Kaczmarek K., Karpiuk M., Melchior C., *A Holistic Approach to Cybersecurity and Data Protection in the Age of Artificial Intelligence and Big Data*, „Prawo i więź” 2024, nr 3(50).
- Kamińska K. H., Cebula M., *Wizualizacja plików binarnych i metody uczenia maszynowego w detekcji i klasyfikacji złośliwego oprogramowania*, „Cybersecurity and Law” 2025, nr 2(14).
- Kaczmarczyk M., *O systemach sztucznej inteligencji w kontekście praw człowieka w orzecznictwie Europejskiego Trybunału Praw Człowieka*, „Studia Prawa Publicznego” 2025, nr 2(50).
- Kosiak P., *Etyczne aspekty rozwoju i wykorzystywania sztucznej inteligencji*, Warszawa 2023.
- Kurp F., *Sztuczna inteligencja od podstaw*, Gliwice 2023.
- Lubasz D., *Przejrzystość i wyjaśnialność sztucznej inteligencji i ich funkcje w RODO i AI Act*, „Monitor Prawniczy” 2024, nr 11.
- Lubasz D., Szkurlat A., *Relacja aktu o sztucznej inteligencji i ogólnego rozporządzenia o ochronie danych*, MoP 21/2022 (dodatek).
- Martini M., Wendehorst Ch. (red.), *KI-VO: Verordnung über Künstliche Intelligenz. Kommentar*, München 2024.
- Mikolov T., Chen K., Corrado G., Dean J., *Efficient Estimation of Word Representations in Vector Space*, arXiv:1301.3781, 2013, <https://arxiv.org/abs/1301.3781> [dostęp: 21.02. 2026].
- Mosqueira-Rey E., Hernández-Pereira E., Alonso-Ríos D., Bobes-Bascarán J., Fernández-Leal Á., *Human-in-the-Loop Machine Learning: A State of the Art*, „Artificial Intelligence Review” 2023, vol. 56(4).
- Parasuraman R., Manzey D. H., *Complacency and Bias in Human Use of Automation*, Human Factors: The Journal of the Human Factors and Ergonomics Society, Santa Monica 2010.
- Pehlivan C. N., Forgó N., P. Valcke (red.), *The EU's Artificial Intelligence (AI) Act. A Commentary*, Alphen aan den Rijn 2025.
- Reimers N., Gurevych I., *Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks*, arXiv:1908.10084, 2019, <https://arxiv.org/abs/1908.10084> [dostęp: 21.02. 2026].
- Wendt J., Wendt D. H., *Das neue Recht der Künstlichen Intelligenz Artificial Intelligence Act (AI Act)*, Baden Baden 2024.
- Voigt P., Hullen N., *Handbuch KI-Verordnung. FAQ zum AI Act*, Berlin 2024.