

Łukasz Jankowski
Rafał Jankowski
Olga Okrzesik
Andrzej Paliński
Piotr Potiopa
Agnieszka Zielińska
Anna Zielińska

Wpływ rozwoju sztucznej inteligencji na informatyczne systemy zarządzania

Pod redakcją
Andrzeja Palińskiego



WYDAWNICTWA AGH
KRAKÓW 2025

Wydawnictwa Akademii Górniczo-Hutniczej im. Stanisława Staszica w Krakowie

© Wydawnictwa AGH, Kraków 2025

Publikacja może być rozpowszechniana zgodnie z licencją Creative Commons CC BY 4.0

ISBN 978-83-68219-55-5 (PDF)

<https://doi.org/10.7494/978-83-68219-55-5>

Recenzenci: *dr hab. inż. Natalia Iwaszczuk, prof. AGH*
dr hab. Marcin Jakubiec, prof. UBB

Afiliacja redaktora i autorów
AGH Akademia Górniczo-Hutnicza
Wydział Zarządzania

Projekt okładki i strony tytułowej: *Alicja Pronobis*

Opieka wydawnicza (rozdz. 1–6): *Agnieszka Rusinek*

Skład: *Wydawnictwo JAK*, www.wydawnictwojak.pl

Wydawnictwa AGH
al. A. Mickiewicza 30, 30-059 Kraków
tel. 12 617 32 28, 12 636 40 38
e-mail: redakcja@wydawnictwoagh.pl
www.wydawnictwo.agh.edu.pl

Spis treści

Wstęp	5
1. Informatyczne systemy zarządzania w MŚP w Polsce	9
1.1. Pojęcie, klasyfikacja i charakterystyka informatycznych systemów zarządzania	9
1.2. Wykorzystanie ISZ w MŚP.....	11
1.3. Wdrażanie informatycznych systemów zarządzania – motywacje, bariery oraz wpływ na funkcjonowanie przedsiębiorstw	15
1.4. Rekomendacje.....	18
2. Informatyczne systemy zarządzania w branży windykacyjnej	20
2.1. Transformacja cyfrowa jako kontekst rozwoju systemów zarządzania w windykacji.....	20
2.2. Informatyczne systemy zarządzania w sektorze windykacyjnym	21
2.3. Wpływ rozwoju sztucznej inteligencji na informatyczne systemy zarządzania w branży windykacyjnej	26
2.4. Przyszłość windykacji masowej: automatyzacja, dane i decyzje oparte na AI.....	28
3. Wykorzystanie technologii AI w zarządzaniu pismami procesowymi	30
3.1. Rola etapu postępowania w strukturze dokumentacyjnej	30
3.2. Przebieg procesu – rys historyczny	31
3.3. Zastosowanie AI/ML w zarządzaniu pismami procesowymi	33
3.4. Prototyp systemu zarządzania pismami procesowymi w spółce windykacyjnej	37
3.5. Analiza ekonomiczna wdrożenia prototypu systemu zarządzania pismami procesowymi	41
4. Uczenie maszynowe na zbiorach niezbalansowanych w problemach zarządzania	43
4.1. Metodyka przetwarzania niezbalansowanych danych	43
4.2. Zbiór danych i metodyka badań.....	47
4.3. Wyniki badań	50
4.4. Wnioski i rekomendacje w procesie uczenia na zbiorach niezbalansowanych.....	55

5. Analiza i cyfrowe zarządzanie komunikacją w organizacji	57
5.1. Historia narzędzi zarządzania komunikacją interpersonalną	57
5.2. Model OCEAN i testy psychometryczne z wykorzystaniem metod AI	59
5.3. Miary rzetelności testów psychometrycznych	61
5.4. Optymalizacja komunikacji w organizacji za pomocą AI	62
6. Zarządzanie procesem ładowania pojazdu elektrycznego z użyciem elementów technologii blockchain	65
6.1. Elektromobilność i blockchain.....	65
6.2. Wpływ technologii blockchain na rozwój infrastruktury ładowania EV.....	70
6.3. Bezpieczeństwo danych i prywatność użytkowników w systemach blockchain dla EV	71
6.4. Handel peer-to-peer w zarządzaniu energią w procesie ładowania pojazdu elektrycznego.....	72
6.5. Nowe możliwości synergii.....	73
7. Sztuczna inteligencja – czy prawo może uczynić AI bardziej ludzką?	75
7.1. Rys historyczny – perspektywa Unii Europejskiej	75
7.2. Konsultacje społeczne	76
7.3. Konkretyzacja środków prawnych	78
7.4. Ocena europejskiej koncepcji legislacyjnej	83
Zakończenie	85
Bibliografia	87

Wstęp

Transformacja cyfrowa, której jesteśmy świadkami na przestrzeni ostatnich dwóch dekad, zmieniła paradygmaty zarządzania organizacjami w niemal każdej dziedzinie działalności gospodarczej, administracyjnej i społecznej. Na czoło tej transformacji wysunęły się technologie informatyczne, a szczególnie te skupione wokół przetwarzania informacji, automatyzacji procesów i podejmowania decyzji. Współczesne organizacje niezależnie od skali działania, sektora czy charakteru prowadzonej działalności coraz powszechniej opierają swoją efektywność operacyjną i strategiczną na zaawansowanych informatycznych systemach zarządzania (ISZ).

Systemy informatyczne, ewoluujące od prostych baz danych do złożonych, wielowymiarowych rozwiązań klasy ERP, CRM, BPM czy BI, stały się nie tylko narzędziami wspierającymi codzienną pracę, ale także fundamentami zarządzania wiedzą, przewagi konkurencyjnej i cyfrowej tożsamości organizacji. Coraz częściej jednak pojawia się pytanie – czy rozwój informatycznych systemów zarządzania przebiega jedynie w obrębie technologii klasycznych, czy też zmierza w stronę głębszej symbiozy z algorytmami sztucznej inteligencji (AI)? Odpowiedź wydaje się jednoznaczna – to właśnie AI staje się czynnikiem redefiniującym zarówno architekturę systemów informatycznych, jak i sposób ich funkcjonowania w praktyce zarządczej.

Zdolność algorytmów do uczenia się na podstawie danych, przetwarzania języka naturalnego, rozpoznawania obrazów, a także podejmowania decyzji w warunkach niepełnej informacji powoduje, że sztuczna inteligencja staje się nieodzownym elementem nowoczesnych rozwiązań informatycznych. W tym kontekście informatyczne systemy zarządzania nie tylko przystosowują się do nowych technologii, ale ulegają fundamentalnej przemianie. Systemy klasy ERP uczą się optymalizować łańcuchy dostaw w czasie rzeczywistym, systemy CRM przewidują zachowania klientów, a narzędzia analityczne typu BI dostarczają dynamicznych scenariuszy wspomagających decyzje strategiczne na podstawie danych predykcyjnych.

Wprowadzenie AI do informatycznych systemów zarządzania to jednak nie tylko szansa, lecz także wyzwanie. Pojawiają się pytania o bezpieczeństwo danych, odpowiedzialność za decyzje podejmowane przez algorytmy, możliwość audytu działań systemu, a także o dostosowanie prawa i etyki do nowego porządku cyfrowego. Szczególnie interesujące w tym kontekście jest zastosowanie AI w sektorach podlegających silnym regulacjom, takich jak finanse, prawo czy energetyka, gdzie automatyzacja musi iść w parze z przejrzystością i zgodnością z przepisami.

Celem niniejszej monografii jest zbadanie wpływu rozwoju sztucznej inteligencji na informatyczne systemy zarządzania. Autorzy przyjmują podejście interdyscyplinarne, łącząc aspekty technologiczne, ekonomiczne, prawne oraz organizacyjne. Na podstawie badań empirycznych, przeglądów literatury i analiz przypadków autorzy starają się odpowiedzieć na pytania:

- Jakie zmiany w architekturze i funkcjonalności ISZ zachodzą pod wpływem rozwoju sztucznej inteligencji?
- W jakich sektorach integracja ISZ z AI przynosi największe korzyści?
- Jakie są bariery implementacji rozwiązań AI w ISZ w polskich realiach?
- W jaki sposób prawo może i powinno regulować stosowanie AI w systemach zarządzania?

Monografia składa się z siedmiu rozdziałów oraz zakończenia, które wspólnie tworzą całościowy obraz wpływu sztucznej inteligencji na rozwój i funkcjonowanie informatycznych systemów zarządzania.

W rozdziale pierwszym autorzy analizują wykorzystanie informatycznych systemów zarządzania w mikro-, małych i średnich przedsiębiorstwach (MŚP) w Polsce. Szczególną uwagę poświęcono typom wdrażanych systemów, barierom implementacyjnym oraz wpływowi ISZ na efektywność działalności przedsiębiorstw. Rozdział ten oparty jest na badaniach empirycznych, co czyni go ważnym punktem odniesienia do dalszych analiz.

Rozdział drugi skupia się na specyfice wdrażania ISZ w branży windykacyjnej. Przedstawiono w nim zastosowanie systemów CRM, ERP, BPM i DMS w procesach windykacji wierzytelności masowych. Szczególne miejsce zajmuje analiza wpływu sztucznej inteligencji na automatyzację i personalizację działań windykacyjnych, w tym także na stosowanie AI w analizie danych i segmentacji klientów.

Rozdział trzeci przedstawia innowacyjne podejście do zarządzania dokumentacją prawną przy użyciu technologii AI. Autorzy opisują prototyp systemu do automatycznego klasyfikowania i zarządzania pismami procesowymi w spółce windykacyjnej oraz przeprowadzają analizę opłacalności wdrożenia tego typu rozwiązań w praktyce.

W rozdziale czwartym omówiono zagadnienia związane z wykorzystaniem metod uczenia maszynowego w kontekście zbiorów danych niezbalansowanych. Przedstawiono badania empiryczne i metody przetwarzania takich zbiorów, co ma znaczenie m.in. w klasyfikacji klientów, analizie ryzyka czy optymalizacji decyzji operacyjnych w ISZ.

Rozdział piąty poświęcono cyfrowemu zarządzaniu komunikacją w organizacjach. Autorzy ukazują historię i ewolucję narzędzi komunikacyjnych, a także rolę AI w interpretacji i optymalizacji komunikacji interpersonalnej w środowisku korporacyjnym. Szczególne miejsce zajmuje tu analiza wykorzystania testów psychometrycznych i modelu OCEAN w połączeniu z metodami AI.

W rozdziale szóstym analizowane jest zastosowanie technologii blockchain w połączeniu z AI do zarządzania procesem ładowania pojazdów elektrycznych. Autorzy wskazują na możliwości decentralizacji, transparentności i bezpieczeństwa wynikające z takich rozwiązań, szczególnie w kontekście energetyki rozproszonej i inteligentnych sieci energetycznych.

Rozdział siódmy przedstawia perspektywę prawną i etyczną. Poruszane są w nim zagadnienia związane z legislacją unijną, konsultacjami społecznymi i normami etycznymi dotyczącymi rozwoju i wdrażania sztucznej inteligencji. Autorzy stawiają pytanie o możliwość

„uczłowieczenia” AI dzięki odpowiednim regulacjom prawnym i zasadom odpowiedzialności algorytmicznej.

Zamykając monografię zakończenie prezentuje kluczowe wnioski, akcentuje znaczenie zrównoważonego podejścia do wdrażania AI w ISZ oraz proponuje kierunki dalszych badań i rozwoju praktyk wdrożeniowych. Monografia stanowi zatem próbę kompleksowego i wieloaspektowego ujęcia wpływu sztucznej inteligencji na współczesne systemy zarządzania w kontekście zarówno praktycznym, jak i teoretycznym.

1. Informatyczne systemy zarządzania w MŚP w Polsce

1.1. Pojęcie, klasyfikacja i charakterystyka informatycznych systemów zarządzania

Współczesne realia gospodarcze, naznaczone rosnącą konkurencją, cyfryzacją oraz zmiennością otoczenia rynkowego, stawiają przed przedsiębiorstwami nowe wyzwania w zakresie efektywnego zarządzania. Informatyczne systemy zarządzania (ISZ), m.in. takie jak: systemy klasy ERP (*Enterprise Resource Planning*), CRM (*Customer Relationship Management*) czy BI (*Business Intelligence*), stają się kluczowymi narzędziami wspierającymi procesy decyzyjne, kontrolne i analityczne w organizacjach różnej wielkości. Technologie informacyjne przekształciły tradycyjne modele biznesowe, umożliwiając integrację danych i procesów na niespotykaną dotąd skalę (Laudon i Laudon 2020).

Znaczenie cyfrowych narzędzi w zarządzaniu szczególnie widoczne jest w sektorze mikro-, małych i średnich przedsiębiorstw (MŚP), które w Polsce stanowią 99% wszystkich aktywnych podmiotów gospodarczych i zatrudniają ponad 6,7 mln osób (Skowrońska 2023). Ich rola w kształtowaniu konkurencyjności gospodarki, generowaniu miejsc pracy oraz wzmacnianiu rozwoju regionalnego została wielokrotnie podkreślona w literaturze (Lachiewicz i in. 2021). MŚP są jednak grupą szczególnie narażoną na ograniczenia w dostępie do nowoczesnych technologii, co wynika z mniejszych możliwości inwestycyjnych, braku wykwalifikowanych specjalistów oraz niskiego poziomu dojrzałości cyfrowej (Boguszewski i in. 2024).

Wdrożenie informatycznych systemów zarządzania może znacząco zwiększyć efektywność operacyjną MŚP, przyczyniając się m.in. do: poprawy przepływu informacji, redukcji kosztów, zwiększenia elastyczności produkcji czy wzrostu satysfakcji klientów (Bodys 2019; Jagielski 2018). Jednak proces ten wiąże się również z szeregiem barier – technicznych, finansowych i organizacyjnych – które mogą ograniczać skalę i skuteczność implementacji. Jak wskazuje Ziemia (2017), sukces wdrożenia ISZ w MŚP zależy w dużej mierze od dopasowania systemu do specyfiki organizacyjnej firmy, a nie od stopnia jego zaawansowania technologicznego.

Małe i średnie przedsiębiorstwa różnią się od dużych firm strukturą organizacyjną, poziomem specjalizacji oraz budżetami inwestycyjnymi. W związku z tym podejście do wdrażania ISZ w MŚP jest zwykle selektywne i etapowe (Lachiewicz i in. 2021). Zamiast wdrażać kompleksowe systemy ERP firmy często decydują się na rozwiązania dopasowane do konkretnego obszaru działalności (np. system CRM do sprzedaży, system WMS do

magazynu itd.). Według Nogalskiego i współautorów (2004) wdrożenia ISZ w MŚP często mają charakter minimalistyczny – obejmują podstawowe funkcjonalności, których działanie nie zakłóca dotychczasowych procesów, a jednocześnie przynosi szybki zwrot z inwestycji.

Informatyczne systemy zarządzania (ISZ) to kompleksowe rozwiązania technologiczne wspierające przedsiębiorstwa w planowaniu, monitorowaniu i usprawnianiu działalności operacyjnej oraz strategicznej. Są one nieodzownym elementem nowoczesnej organizacji, ponieważ umożliwiają integrację danych, procesów oraz zasobów w jednej spójnej strukturze (Laudon i Laudon 2020).

ISZ można klasyfikować według różnych kryteriów, m.in.: funkcji biznesowej, obszaru zastosowania czy poziomu integracji. W kontekście MŚP wybór systemu zależy nie tylko od potrzeb operacyjnych, ale również od dostępnych zasobów finansowych i kompetencji technologicznych przedsiębiorstwa (Skowrońska 2023).

W literaturze przedmiotu wyróżnia się wiele kategorii ISZ zróżnicowanych pod względem funkcji i obszaru zastosowania. Do najczęściej omawianych należą (Bodys 2019; Nogalski i in. 2004; Skowrońska 2023):

- Systemy klasy ERP (*Enterprise Resource Planning*) – integrują najważniejsze obszary działalności firmy: finanse, produkcję, zaopatrzenie, kadry, magazyn, sprzedaż. Charakteryzują się modułową budową, co umożliwia ich wdrażanie etapowe, zgodnie z potrzebami i możliwościami przedsiębiorstwa. W MŚP ERP często stosowane są jako platforma do gromadzenia i przetwarzania danych z różnych działów. Korzyściami są m.in. poprawa przepływu informacji, redukcja błędów i lepsza kontrola nad procesami.
- Systemy CRM (*Customer Relationship Management*) – umożliwiają zarządzanie bazą klientów, historią kontaktów, kampaniami marketingowymi oraz procesem sprzedaży. W małych firmach CRM może pełnić funkcję narzędzia codziennej pracy handlowców, wspierając personalizację oferty oraz zwiększenie lojalności klientów. Rozwiązania te często są dostępne w modelu SaaS (Software as a Service), co ułatwia wdrożenie i obniża koszt inwestycji (Prymon-Ryś 2023).
- Systemy BPM (*Business Process Management*) – to podejście do zarządzania przedsiębiorstwem przez identyfikację, modelowanie, analizę i optymalizację procesów biznesowych. Systemy BPM wspierają m.in. automatyzację obiegu dokumentów, nadzór nad procedurami czy wdrażanie standaryzacji (A`yun i Prihartono 2025). Wdrożenie systemu BPM w MŚP pozwala na uporządkowanie działań operacyjnych oraz skrócenie czasu reakcji na zmiany otoczenia.
- Systemy BI (*Business Intelligence*) – to szczególna kategoria systemów ISZ, która skupia się na przetwarzaniu danych w celu dostarczania informacji wspierających podejmowanie decyzji, przez raportowanie, analizy porównawcze, prognozy i wizualizację danych. Zastosowanie BI w MŚP pozwala na szybsze wykrywanie nieprawidłowości, identyfikację trendów oraz poprawę efektywności strategicznej (Kimball i Ross 2013). Narzędzia te stają się coraz bardziej dostępne dzięki technologiom chmurowym i prostym interfejsom, co umożliwia ich wdrażanie nawet w firmach o ograniczonych zasobach IT (Cieplak i Małysek 2019).
- Systemy SCM (*Supply Chain Management*) – wspierają zarządzanie przepływem surowców, półproduktów i wyrobów gotowych – od dostawców aż po klienta finalnego.

W MŚP mają zastosowanie przede wszystkim w przedsiębiorstwach produkcyjnych lub dystrybucyjnych, gdzie efektywność logistyki wpływa bezpośrednio na koszty i jakość obsługi klienta (Barcik i Jakubiec 2011). Integracja SCM z ERP umożliwia efektywną integrację zapasów i dostaw.

- Systemy klasy MRP I (*Material Requirements Planning*) i MRP II (*Manufacturing Resource Planning*) – to systemy do planowania zapotrzebowania na materiał. MRP uwzględnia dane o stanach magazynowych, planach sprzedaży oraz czasach realizacji zamówień (Shamsuzzoha i Jaakkola 2024). Jest szczególnie przydatny w firmach produkcyjnych, gdzie ograniczenie braków materiałowych przekłada się na efektywność całego procesu.
- Systemy WMS (*Warehouse Management System*) – umożliwiają precyzyjne zarządzanie magazynem: lokalizacjami, ruchem towarów, stanami magazynowymi i inwentaryzacją. Umożliwiają m.in. śledzenie partii, automatyczne przyjęcia i wydania, etykietowanie czy integrację ze skanerami kodów kreskowych (Shanmugamani i Mohamad 2023). W MŚP wdrażane są coraz częściej ze względu na wzrost oczekiwań klientów w zakresie czasu realizacji zamówień.

Systemy te mogą funkcjonować niezależnie lub w ramach jednej zintegrowanej platformy, co pozwala przedsiębiorstwom na elastyczne dopasowanie narzędzi do ich aktualnych potrzeb i zasobów.

1.2. Wykorzystanie ISZ w MŚP

Celem badania było rozpoznanie poziomu wykorzystania informatycznych systemów zarządzania (ISZ) w sektorze małych i średnich przedsiębiorstw w Polsce, identyfikacja najczęściej stosowanych typów systemów (m.in.: ERP, CRM, WMS, MRP, BPM, BI), a także analiza motywacji i barier związanych z ich wdrażaniem. Dodatkowo badanie miało ocenić wpływ ISZ na funkcjonowanie operacyjne przedsiębiorstw oraz ich efektywność w zakresie zarządzania zasobami, procesami i relacjami z klientami. W ramach badań sformułowano następujące pytania badawcze:

- Jakie typy systemów informatycznych są najczęściej wykorzystywane w polskich MŚP?
- Jakie są główne cele i motywacje wdrażania ISZ?
- Jakie bariery napotykają przedsiębiorstwa w procesie wdrażania systemów?
- Czy i w jakim stopniu ISZ wpływają na poprawę efektywności funkcjonowania firm?

Na potrzeby analizy przyjęto następującą hipotezę badawczą: implementacja informatycznych systemów zarządzania w MŚP przyczynia się do wzrostu efektywności operacyjnej i jakości procesów decyzyjnych.

W badaniu zastosowano podejście ilościowe, wykorzystując jako główne narzędzie kwestionariusz ankiety. Metoda ta została wybrana ze względu na możliwość zebrania danych od dużej liczby respondentów i przeprowadzenia porównań statystycznych. Kwestionariusz przygotowano w wersji elektronicznej i rozdystrybuowano za pośrednictwem platform internetowych, forów branżowych oraz bezpośrednich kontaktów z przedsiębiorcami.

Kwestionariusz składał się z trzech głównych części:

- 1) Informacje ogólne o przedsiębiorstwie (metryczka) – pytania dotyczące branży, wielkości zatrudnienia, lokalizacji, czasu działania na rynku, formy własności oraz poziomu cyfryzacji.
- 2) Zakres wykorzystania systemów ISZ – pytania o stosowane systemy (ERP, CRM, BI, MRP, WMS, BPM), ich funkcje, obszary zastosowania, sposoby finansowania oraz stopień integracji z innymi narzędziami.
- 3) Ocena wpływu systemów ISZ – pytania miały na celu ustalenie, czy wdrożone systemy przyniosły poprawę w zakresie efektywności pracy, redukcji błędów, szybkości obsługi klienta, jakości decyzji zarządczych i wzrostu przychodów.

Większość pytań miała charakter zamknięty (jednokrotnego lub wielokrotnego wyboru), a w ocenie subiektywnych opinii zastosowano pięciostopniową skalę Likerta (od 1 – „zdecydowanie się nie zgadzam” do 5 – „zdecydowanie się zgadzam”).

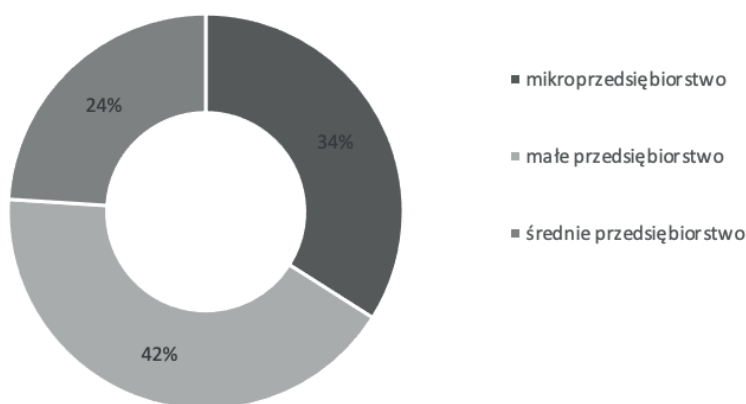
Badanie przeprowadzono w trzecim kwartale 2024 roku wśród polskich przedsiębiorstw spełniających kryteria MŚP. Próba badawcza miała charakter celowy – liczba poprawnie wypełnionych ankiet wyniosła 247 i uwzględniono w niej firmy z różnych branż i regionów kraju.

Charakterystyka próby badawczej została przedstawiona poniżej, w podziale na kluczowe zmienne opisujące strukturę i profil uczestniczących firm.

Struktura próby badawczej według wielkości zatrudnienia była zgodna z kryteriami klasyfikacyjnymi MŚP przyjętymi przez Komisję Europejską:

- mikroprzedsiębiorstwa (1–9 pracowników): 34% ($n = 84$),
- małe przedsiębiorstwa (10–49 pracowników): 42% ($n = 104$),
- średnie przedsiębiorstwa (50–249 pracowników): 24% ($n = 59$).

Strukturę zaprezentowano na rysunku 1.1. Uwzględnia ona zarówno najmniejsze podmioty, jak i firmy o bardziej rozwiniętych strukturach organizacyjnych.



Rys. 1.1. Struktura badanych przedsiębiorstw

Przedsiębiorstwa uczestniczące w badaniu reprezentowały różne sektory gospodarki. Rozkład branż wyglądał następująco:

- usługi (np. doradztwo, edukacja, transport, gastronomia): 37%,
- produkcja (w tym produkcja przemysłowa, rzemiosło, przetwórstwo): 26%,
- handel (hurtowy i detaliczny): 24%,
- IT i technologie cyfrowe: 13%.

Zróźnicowanie branżowe umożliwiło analizę stopnia informatyzacji w różnych kontekstach działalności gospodarczej.

Respondenci pochodzili z całego kraju, jednak największy udział miały firmy z następujących województw:

- mazowieckie: 22%,
- śląskie: 15%,
- dolnośląskie: 13%,
- wielkopolskie: 12%,
- pozostałe województwa: 38% łącznie.


Oznacza to, że badanie objęło zarówno silnie zurbanizowane regiony, jak i mniejsze ośrodki, co sprzyja analizie wpływu lokalizacji na dostępność technologii i tempo wdrażania ISZ.

Firmy uczestniczące w badaniu różniły się również pod względem długości funkcjonowania na rynku:

- do 5 lat: 19%,
- 6–10 lat: 31%,
- 11–20 lat: 28%,
- powyżej 20 lat: 22%.

Dane te sugerują, że zarówno nowe, jak i doświadczone firmy interesują się wdrażaniem rozwiązań informatycznych – choć podejścia do ISZ mogą różnić się w zależności od stażu rynkowego.


Respondenci ocenili poziom informatyzacji swojej firmy na pięciostopniowej skali Likerta. Wyniki zaprezentowano na rysunku 1.2.



Rys. 1.2. Poziom informatyzacji przedsiębiorstw

Blisko połowa przedsiębiorstw deklaruje wysoki poziom informatyzacji, co może świadczyć o rosnącej świadomości technologicznej wśród polskich MŚP. Jednocześnie jedno przedsiębiorstwo na pięć znajduje się w początkowej fazie cyfrowej transformacji.

Na pytanie o dotychczasowe wdrożenia systemów informatycznych respondenci wskazali systemy wykorzystywane w ich przedsiębiorstwach (rys. 1.3).



Rys. 1.3. Wdrożenie systemów informatycznych

Oznacza to, że niemal cztery przedsiębiorstwa na pięć korzystają z przynajmniej jednego typu systemu ISZ. Najczęściej wdrażane są systemy ERP i CRM, co jest zgodne z trendami globalnymi i europejskimi, gdzie narzędzia te stanowią fundament cyfrowego zarządzania procesami operacyjnymi i obsługą klienta. Co istotne, badanie pokazało również wzrost wykorzystania narzędzi analitycznych klasy BI oraz specjalistycznych systemów jak WMS i MRP (zwłaszcza w średnich przedsiębiorstwach). Może to świadczyć o dojrzewaniu cyfrowym polskich MŚP i o potrzebie dostępu do danych w czasie rzeczywistym, nie tylko w celach operacyjnych, ale również strategicznych.

Charakterystyka badanej grupy wskazuje, że polskie MŚP to zróżnicowane środowisko pod względem skali działania, branży, doświadczenia rynkowego i poziomu cyfryzacji. Rosnie liczba przedsiębiorstw zainteresowanych wdrażaniem ISZ, przy czym nadal występuje grupa przedsiębiorstw o niskim poziomie informatyzacji. Wyniki te stanowią podstawę do dalszej analizy czynników wpływających na wdrażanie systemów oraz ich oddziaływanie na efektywność organizacyjną. Wyniki przeprowadzonego badania potwierdzają, że informatyczne systemy zarządzania (ISZ) odgrywają coraz większą rolę w funkcjonowaniu polskich przedsiębiorstw. Mimo różnic w poziomie informatyzacji znaczna część firm deklaruje wykorzystanie przynajmniej jednego typu systemu ISZ.


1.3. Wdrażanie informatycznych systemów zarządzania – motywacje, bariery oraz wpływ na funkcjonowanie przedsiębiorstw

Analiza została pogrupowana według głównych obszarów tematycznych: stosowanie systemów ISZ, motywacje wdrożeniowe, napotymane bariery oraz wpływ wdrożeń na funkcjonowanie przedsiębiorstwa.

Wśród respondentów dominowały przedsiębiorstwa, które już wdrożyły przynajmniej jeden typ systemu informatycznego. Najczęściej stosowane są systemy klasy ERP i CRM, co potwierdza ich uniwersalność i szerokie zastosowanie w różnych branżach. Warto jednak podkreślić wzrost zainteresowania rozwiązaniami analitycznymi (BI) oraz specjalistycznymi narzędziami wspierającymi produkcję i magazynowanie (MRP, WMS), szczególnie wśród firm średniej wielkości.

Respondenci wskazywali różnorodne cele (motywacje) wdrażania systemów ISZ (rys 1.4), w tym takie jak:

- poprawa organizacji pracy i przepływu informacji – 67%,
- zwiększenie kontroli nad procesami – 59%,
- poprawa jakości obsługi klienta – 54%,
- konieczność spełnienia wymagań kontrahentów – 31%,
- automatyzacja procesów i redukcja kosztów – 45%,
- zwiększenie konkurencyjności – 37%.



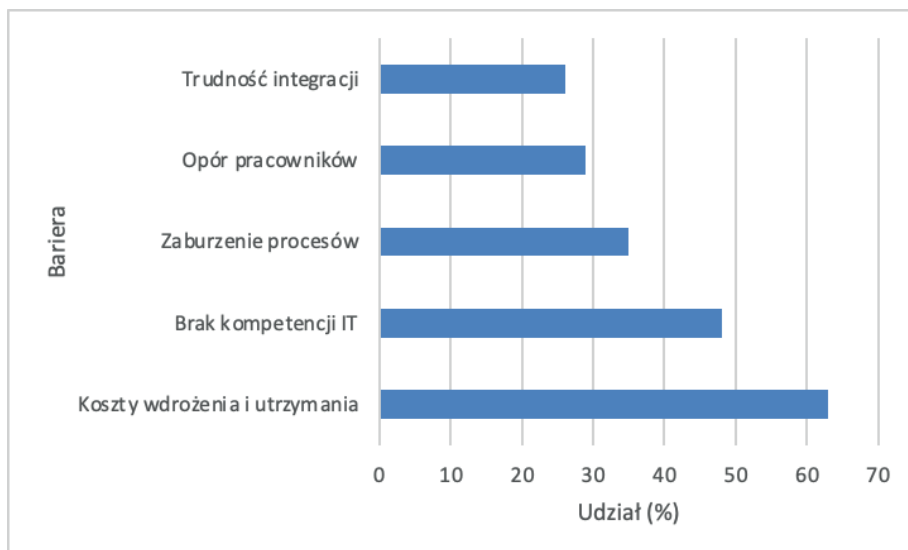
Rys. 1.4. Motywacje wdrażania ISZ

Wyniki wskazują, że wdrażanie systemów ISZ w MŚP ma charakter nie tylko operacyjny (efektywność), ale też strategiczny (dostosowanie do rynku i klientów).

Wśród głównych motywacji do wdrażania ISZ respondenci wskazywali przede wszystkim potrzebę poprawy organizacji pracy oraz lepszej kontroli nad procesami. Ten pragmatyczny aspekt wdrożeń systemowych jest zgodny z obserwacjami Laudonów (2020), którzy twierdzą, że informatyzacja w MŚP nie wynika najczęściej z modnych trendów, lecz z realnych potrzeb efektywnościowych. Jednocześnie znacząca część firm zauważa wpływ wdrożeń na relacje z klientami i wzrost konkurencyjności, co wpisuje się w koncepcję tzw. cyfrowej przewagi operacyjnej.

Pomimo korzyści wiele MŚP nadal napotyka trudności we wdrażaniu ISZ. Wśród najczęściej wskazywanych barier (rys. 1.5) znalazły się:

- wysokie koszty wdrożenia i utrzymania – 63%,
- brak kompetencji IT w zespole – 48%,
- obawy przed zaburzeniem dotychczasowych procesów – 35%,
- opór pracowników wobec zmian – 29%,
- trudność w integracji z istniejącymi rozwiązaniami – 26%,
- niedostosowanie gotowych systemów do specyfiki firmy (odpowiedź kilku respondentów).




Rys. 1.5. Bariery wdrażania ISZ

Wyniki pokazują, że choć technologia jest coraz bardziej dostępna, to bariery organizacyjne i kompetencyjne pozostają istotnym wyzwaniem dla MŚP. Zwłaszcza wysokie koszty oraz brak kompetencji IT stanowią istotne ograniczenie dalszej cyfryzacji. Te problemy są konsekwentnie opisywane w literaturze przedmiotu i rozpatrywane w kontekście sukcesu wdrożenia systemu informatycznego zależnego nie tylko od technologii, ale przede wszystkim od gotowości organizacyjnej i kompetencyjnej firmy. Wyniki badań potwierdzają, że w MŚP nadal brakuje wsparcia doradczego i edukacyjnego w zakresie wyboru i implementacji ISZ.

Wdrożenie systemu informatycznego bez przygotowania organizacyjnego może skutkować porażką nawet przy wysokiej jakości samego rozwiązania technologicznego.

Respondenci, którzy wdrożyli systemy ISZ, zostali poproszeni o ocenę wpływu tych rozwiązań na konkretne aspekty funkcjonowania przedsiębiorstwa. Wyniki przedstawione zostały na rysunku 1.6 (średnia w skali Likerta 1–5).



Rys. 1.6. Ocena wpływu ISZ na działalność MŚP

Wysokie średnie oceny wskazują, że respondenci postrzegają ISZ jako narzędzie realnie wspierające efektywność organizacyjną i operacyjną (na pierwszy miejscu szybkość obsługi klienta).

Prawdopodobnie wysokie oceny wpływu systemów ISZ na efektywność operacyjną i decyzyjną firmy wynikają z podejścia, zgodnie z którym nawet częściowe wdrożenie informatycznych systemów zarządzania może znacząco poprawić procesy wewnętrzne, zmniejszyć liczbę błędów i poprawić jakość usług. Potwierdzono także istnienie zależności między wielkością firmy a zakresem stosowanych systemów – większe przedsiębiorstwa częściej wdrażają złożone rozwiązania (ERP, BI, WMS), co koreluje z ich zasobami finansowymi i kadrowymi.

Ciekawym wnioskiem jest również zróżnicowanie podejścia do wdrażania systemów – mikroprzedsiębiorstwa często korzystają z gotowych rozwiązań, tanich i prostych w obsłudze (np. oprogramowania CRM w modelu SaaS – chmurowym), podczas gdy średnie firmy częściej decydują się na systemy modułowe, dostosowane do ich specyfiki i skali działania.

Z analizy statystycznej (test ANOVA, $p < 0,05$) wynika, że im większa firma (w sensie liczby zatrudnionych pracowników), tym większe prawdopodobieństwo wdrożenia systemów klasy ERP, BI i WMS. Mikroprzedsiębiorstwa częściej ograniczają się do CRM lub korzystają z rozwiązań punktowych, niskokosztowych lub open-source'owych.

Weryfikując hipotezę zakładającą, że wdrożenie ISZ przyczynia się do poprawy efektywności działania przedsiębiorstwa, na podstawie uzyskanych danych można stwierdzić, że:

- przedsiębiorstwa korzystające z ISZ deklarują wyższy poziom efektywności operacyjnej,
- wdrożenie systemów koreluje dodatnio z takimi wskaźnikami jak poprawa obsługi klienta, kontrola procesów i jakość danych,
- korzyści są szczególnie wyraźne w przedsiębiorstwach, które zainwestowały w więcej niż jeden typ systemu (np. ERP + BI + CRM).

Tym samym hipoteza badawcza znajduje potwierdzenie w wynikach empirycznych. Zastosowanie ISZ pozwala na zwiększenie efektywności operacyjnej, automatyzację procesów, poprawę jakości danych oraz lepszą kontrolę nad zasobami i działaniami przedsiębiorstwa. Przykładowo:

- ERP eliminuje redundancję danych i usprawnia procesy międzydziałowe,
- CRM pozwala na zwiększenie satysfakcji i lojalności klientów,
- BI wspiera kadrę menedżerską w analizie efektywności działań i podejmowaniu strategicznych decyzji,
- WMS zwiększa dokładność stanów magazynowych i przyspiesza operacje logistyczne,
- BPM pozwala na identyfikację wąskich gardeł i ciągle doskonalenie procesów.

Korzyści te zostały potwierdzone w badaniach empirycznych, także w kontekście polskiego sektora MŚP.

1.4. Rekomendacje

Na podstawie przeprowadzonych badań i analizy literatury przedmiotu sformułowano następujące wnioski.

- Informatyczne systemy zarządzania stają się coraz powszechniejszym narzędziem wspierającym działalność operacyjną i strategiczną polskich MŚP. Ponad 79% badanych firm korzysta z przynajmniej jednego typu systemu ISZ.
- Najczęściej wdrażane systemy to system ERP (42%) i CRM (38%), przy czym widoczny jest wzrost zainteresowania narzędziami analitycznymi (BI) oraz systemami wspierającymi magazynowanie (WMS) i produkcję (MRP).
- Główne motywacje wdrażania systemów to poprawa organizacji pracy, zwiększenie kontroli nad procesami i lepsza obsługa klienta. Wskazuje to na rosnącą świadomość roli technologii jako czynnika usprawniającego działalność.
- Najpoważniejsze bariery to koszty wdrożenia i utrzymania, niedobór kompetencji IT oraz obawy przed zakłóceniem funkcjonowania przedsiębiorstwa. Dotyczy to w szczególności mikroprzedsiębiorstw.
- Respondenci oceniają pozytywnie wpływ ISZ na szybkość obsługi klientów, jakość danych, redukcję błędów i trafność decyzji. Efekty są bardziej odczuwalne w firmach, które wdrożyły więcej niż jeden system.
- Większe przedsiębiorstwa częściej wdrażają zintegrowane systemy (ERP, BI), natomiast mniejsze wybierają rozwiązania modułowe lub dostępne w modelu SaaS (chmurowym).

Zostały stworzone rekomendacje dla przedsiębiorców MŚP, mianowicie:

- rozpoczynanie cyfryzacji od jednego systemu (np. CRM lub ERP) pozwala ograniczyć koszty i zminimalizować ryzyko operacyjne;
- wykorzystywanie rozwiązań chmurowych: systemy w modelu SaaS redukują potrzebę inwestycji w infrastrukturę i są łatwe do skalowania;
- przeszkolenie pracowników z obsługi systemów zwiększa efektywność wdrożenia i ogranicza opór przed zmianą.

Natomiast rekomendacje dla dostawców technologii są następujące:

- oferta dostosowana do potrzeb MŚP, czyli: elastyczne licencjonowanie, wersje modułowe oraz prosty interfejs użytkownika;
- wsparcie wdrożeniowe: dla przedsiębiorcy istotna jest nie tylko technologia, ale również sposób implementacji (konsulting, onboarding i szkolenia).

Wyniki badania dostarczają więc dowodów na to, że ISZ mogą pełnić funkcję nie tylko wspierającą, ale również transformacyjną w kontekście rozwoju MŚP. Jednocześnie wskazują na potrzebę działań systemowych – zarówno ze strony dostawców technologii, jak i instytucji wspierających sektor MŚP – mających na celu obniżenie barier wejścia, poprawę dostępności szkoleń oraz promocję dobrych praktyk wdrożeniowych.

2. Informatyczne systemy zarządzania w branży windykacyjnej

2.1. Transformacja cyfrowa jako kontekst rozwoju systemów zarządzania w windykacji

Podmioty windykacyjne, z założenia zajmujące się zarówno zarządzaniem, jak i procesem windykacji wierzytelności, stanęły przed nowymi wyzwaniami będącymi konsekwencją transformacji cyfrowej związanej z automatyzacją procesów i wykorzystaniem sztucznej inteligencji. Procesy operacyjne windykacji wierzytelności, zwłaszcza w modelu windykacji masowej, charakteryzują się dużą złożonością oraz podlegają rygorystycznym regulacjom, w tym przepisom prawnym (Kondracki 2023). Stan ten wymusza na podmiotach windykacyjnych przestrzeganie regulacji prawnych, jak i zachowania właściwej relacji z interesariuszami oraz podejmowanie skutecznych działań windykacyjnych. W celu realizacji wyżej wymienionych działań podmioty windykacyjne – zarówno w przeszłości, jak i obecnie – wykorzystują całe spektrum rozwiązań, klasyfikowanych jako informatyczne systemy zarządzania, ISZ (*Management Information Systems*, MIS) – rozumiane nie tylko w tradycyjnym ujęciu jako zintegrowane systemy informatyczne wspierające procesy zarządzania w organizacjach, ale również jako ich rozwinięcia wymuszone rozwojem sztucznej inteligencji. Zasadniczym celem informatycznych systemów zarządzania w podmiocie windykacyjnym jest ogół działań związanych z gromadzeniem, przetwarzaniem, a następnie udostępnianiem informacji potrzebnych do podejmowania decyzji, zarówno tych na poziomie operacyjnym, jak i strategicznym (Ziemia i Obłąk 2012). Wykorzystanie informatycznych systemów zarządzania umożliwia nie tylko podejmowanie decyzji na różnych szczeblach zarządzania, ale również funkcjonowanie różnych komórek organizacyjnych w podmiocie windykacyjnym, takich jak dział HR, IT, dział prawny, SKIP Tracing.

W tradycyjnym ujęciu w grupie informatycznych systemów zarządzania wymienia się: systemy klasy CRM (*Customer Relationship Management*), systemy ERP (*Enterprise Resource Planning*), systemy wspierające BPM (*Business Process Management*) oraz systemy DMS (*Document Management System*). Wymienione systemy usprawniające organizację pracy, przetwarzanie dokumentów oraz obsługę wybranych procesów biznesowych nie wyczerpują zakresu informatycznych systemów zarządzania, zwłaszcza w czasie transformacji technologicznej związanej z rozwojem sztucznej inteligencji (Oyekunle i Boohene 2024), w której możemy uczestniczyć.

Zrozumienie zarówno możliwości, jak i wyzwań związanych z zastosowaniem sztucznej inteligencji w nowoczesnych organizacjach ma kluczowe znaczenie. Zmiany, jakie przechodzi wiele podmiotów w związku z transformacją technologiczną, obejmujące wykorzystanie innowacyjnych technologii cyfrowych przekładających się na efektywne zarządzanie zasobami i możliwościami, prowadzą również do rozszerzenia podejścia do informatycznych systemów zarządzania. Rozszerzenie to obejmuje zastosowanie sztucznej inteligencji – zarówno bezpośrednio, jak i przez pokrewne techniki, takie jak przetwarzanie języka naturalnego (*Natural Language Processing*, NLP), robotyzację i automatyzację procesów biznesowych (*Robotic Process Automation*, RPA) oraz uczenie maszynowe (*Machine Learning*, ML). Szczególnie zauważalne w branży windykacyjnej lub szerzej – branży finansowej jest zastosowanie uczenia maszynowego w procesie podejmowania decyzji. Jedno z takich zastosowań, wykorzystane do sterowania procesem windykacji wierzytelności masowych za pomocą drzew klasyfikacyjnych, zostanie przybliżone szczegółowo.

Nader często podmioty windykacyjne rozszerzają funkcjonalność o elementy sztucznej inteligencji przez modyfikację lub rozbudowę informatycznych systemów zarządzania, w celu podniesienia efektywności, wzbogacania danych czy też lepszej automatyzacji, tak istotnej przy windykacji dużych portfeli homogenicznych wierzytelności. Na rosnące wykorzystanie sztucznej inteligencji zwraca uwagę także literatura. Dla przykładu badania wykazały, że od 2017 roku liczba organizacji wykorzystujących sztuczną inteligencję przynajmniej w jednym obszarze funkcjonowania przedsiębiorstwa wzrosła blisko czterokrotnie z 20% w 2017 roku do blisko 50% w 2022 roku (McKinsey 2022), a następnie do poziomu blisko 80% w 2024 roku (McKinsey 2025). Analizy przygotowane przez McKinsey & Company w 2025 roku wskazują, że zastosowanie sztucznej inteligencji może przyczynić się do wzrostu produktywności o wartości szacowanej na 4,4 bln USD (wartość podawana wariantowo, w przedziale 2,6–4,4 bln USD) (Kondracki 2023).

2.2. Informatyczne systemy zarządzania w sektorze windykacyjnym

Efektywne zarządzanie procesem windykacji wierzytelności o charakterze masowym stanowi kluczowy czynnik determinujący zarówno opłacalność, jak i skuteczność podejmowania działań windykacyjnych. Windykacja wierzytelności masowych to proces dochodzenia należności z wielu zobowiązań, które zazwyczaj mają niską wartość jednostkową, ale występują w dużej liczbie. Charakterystyczną cechą tego typu wierzytelności jest ich masowy charakter – wynikający najczęściej z działalności abonamentowej, sprzedaży ratalnej, usług finansowych, ubezpieczeniowych oraz dostaw mediów. Skala zjawiska wymusza stosowanie zaawansowanych rozwiązań organizacyjnych i technologicznych, umożliwiających efektywną obsługę dużych wolumenów spraw przy jednoczesnej minimalizacji kosztów jednostkowych (Barszczewska 2016; Jankowski 2023). Stan ten wskazuje na potencjał zastosowania informatycznych systemów zarządzania, wspomaganych elementami sztucznej inteligencji. Zastosowanie informatycznych systemów zarządzania w windykacji wymaga zrozumienia jej przebiegu. Windykacja wierzytelności masowych charakteryzuje się wysokim stopniem proceduralizacji

oraz koniecznością implementacji rozwiązań informatycznych, takich jak zintegrowane systemy CRM, automatyczne systemy komunikacyjne (np. SMS, e-mail, automatyczne połączenia głosowe) oraz platformy wspomagające zarządzanie procesami – np. wykorzystujące notacje BPMN. Z uwagi na ograniczoną rentowność pojedynczych spraw (wiele należności o relatywnie niskich dochodzonych kwotach) kluczowe znaczenie ma zastosowanie narzędzi umożliwiających podejmowanie decyzji na podstawie analizy danych – w tym algorytmów klasyfikacyjnych, scoringowych oraz metod uczenia maszynowego, które pozwalają na segmentację portfela wierzytelności, ocenę ryzyka, optymalizację strategii windykacyjnych oraz zastosowanie rozwiązań bazujących na sztucznej inteligencji (np. przez chatboty), analizę korespondencji itd. W tym modelu proces windykacji wierzytelności masowych podzielono na trzy etapy obejmujące windykację polubowną, sądową i egzekucyjną. Czasami wyróżnia się także windykację przymusową, która łączy etap sądowy i egzekucyjny, oddzielając ją od windykacji polubownej ze względu na zastosowanie środków przymusu prawnego. O skuteczności prowadzonych działań windykacyjnych na każdym z etapów decyduje znajomość uwarunkowań prawnych i ekonomicznych, jak również integracja wiedzy eksperckiej z wiedzą odkrytą w danych wtórnych, co w praktyce przekłada się na zdolność do budowania elastycznych i adaptacyjnych modeli decyzyjnych z wykorzystaniem algorytmów uczenia maszynowego, np. drzew klasyfikacyjnych. Podejście takie daje możliwość zwiększenia skuteczności odzyskiwania należności, a także podniesienia efektywności operacyjnej podmiotów windykacyjnych prowadzących windykację portfeli wierzytelności o charakterze masowym. Tradycyjnie pojmowana automatyzacja w procesie windykacji wierzytelności polega na wykorzystaniu systemów informatycznych do realizacji powtarzalnych czynności przewidzianych do realizacji w procesie obsługi wierzytelności w taki sposób, aby zredukować do minimum zaangażowanie pracowników, bez względu na rozpatrywany etap windykacji. Podstawowym celem tak rozumianej automatyzacji jest zwiększenie efektywności prowadzonych działań, redukcja kosztów, zmniejszenie obciążenia pracowników czynnościami rutynowymi oraz przyspieszenie całego procesu windykacji wierzytelności. Do typowych rozwiązań należą: systemy CRM i platformy do zarządzania wierzytelnościami, automatyczna wysyłka korespondencji (np. e-maile, SMS-y, listy), automatyczne dialery telefoniczne, harmonogramy działań i szablony windykacyjne, a także automatyczne raportowanie i archiwizacja danych. Dzięki takim narzędziom możliwe jest prowadzenie windykacji masowej przy ograniczonym zaangażowaniu zasobów ludzkich, z zachowaniem kontroli nad przebiegiem i skutecznością procesu. Zmiany w sektorze finansowym i trwająca transformacja cyfrowa sprawiają, że podmioty windykacyjne muszą automatyzować procesy i korzystać z różnych informatycznych systemów zarządzania. Wybranych z nich przyjrano się w niniejszym rozdziale.

Systemy CRM, jak już wspomniano, wykorzystywane są w głównej mierze do zarządzania relacji z klientami. W odniesieniu do branży windykacyjnej opis ten można rozszerzyć, traktując interesariuszy jako klientów. Wówczas systemy te wykorzystywane są w odniesieniu do zarówno podmiotów, od których nabywa się pakiety wierzytelności lub na których zlecenie prowadzi się windykację pakietów wierzytelności, jak i osoby dłużnika. W tym ostatnim przypadku systemy uczestniczą w nawiązaniu kontaktu z dłużnikiem w procesie windykacji. Tak zawężone systemy klasy CRM stwarzają możliwość centralnego zarządzania informacjami o uczestnikach procesu windykacji wierzytelności, a także przechowują dane

o charakterze historycznym, dotyczące podejmowanej interakcji pomiędzy interesariuszami. Systemy CRM w zastosowaniach windykacyjnych wykorzystywane są do gromadzenia oraz przechowywania informacji (oprócz danych teleadresowych) o zadłużeniu i przebiegu działań windykacyjnych, a także do harmonogramowania kontaktów z dłużnikiem. Wdrożenie systemów CRM w podmiocie windykacyjnym przynosi dwa główne efekty: zwiększa skuteczność działań wobec dłużników oraz porządkuje podejmowane czynności. Osiąga się to dzięki powiązaniu konkretnych działań, wiarytelności i czynności z osobą dłużnika, np. w formie jego kartoteki. Tym samym systemy klasy CRM wspierają działy windykacji w planowaniu działań, segmentowaniu portfela obsługiwanych wiarytelności oraz finalnie raportowaniu wyników. Współcześnie wykorzystywane w windykacji systemy klasy CRM rozbudowane są o moduły wspierające przygotowanie powiadomień SMS. Dodatkowo połączenie koncepcji CRM ze sztuczną inteligencją stwarza możliwość automatyzacji w procesie generowania spersonalizowanych powiadomień oraz wezwań do zapłaty w stopniu znacznie wyższym, niż miało to miejsce np. przy wykorzystaniu szablonów powiadomień. Wydaje się, że w kontekście wykorzystania systemów CRM w windykacji kluczowe powinno być umożliwienie przez systemy tej klasy personalizacji podejścia do osoby dłużnika z zachowaniem elementów empatii. Oparcie windykacji na cyfrowych kanałach komunikacji, wykorzystujących CRM, prowadzi do realizacji postulatu, w którym dłużnik znajduje się w centrum spersonalizowanego procesu. Ciekawy przykład oraz zaobserwowane efekty wdrożenia klasycznej koncepcji CRM w procesie windykacji czytelnik znajdzie w pracy Wejer-Kudęłko i Kudęłki (2017). Zaznaczyć należy, że w branży windykacyjnej praktykowane jest podejście, w którym poszczególne podmioty, zwłaszcza duże o ugruntowanej pozycji na rynku, zamiast wdrażać gotowe rozwiązania IT, stawiają na autorskie rozwiązania, łącząc w systemach wsparcia windykacji kilka obszarów funkcjonalnych rozumianych jako informatyczne systemy zarządzania.

Zintegrowane systemy informatyczne wykorzystywane do szeroko rozumianego planowania zasobów przedsiębiorstwa oraz zarządzania kluczowymi obszarami działalności są charakterystyczne dla systemów klasy ERP. W podmiocie windykacyjnym systemom klasy ERP przypisywane są dodatkowo funkcje, których zadaniem jest integracja obszarów i danych finansowo-księgowych z danymi zgromadzonymi w trakcie procesu windykacji wiarytelności. W podmiocie windykacyjnym systemy klasy ERP wykorzystywane są jako narzędzie integrujące kluczowe funkcje, zwłaszcza w obszarze łączącym proces windykacji wiarytelności z funkcjami o charakterze finansowym oraz księgowym. Sytuacja taka występuje np. wtedy, gdy podmiot windykacyjny nabywa pakiet wiarytelności masowych, a system klasy ERP wykorzystywany jest do monitoringu posiadanych aktywów – aktualizacji wartości portfela wiarytelności oraz rozliczania spłat dokonywanych przez dłużników. Nieco odmiennie wyglądałoby funkcjonowanie systemów klasy ERP w przypadku, w którym podmiot windykacyjny prowadziłby windykację w modelu usługowym, np. na zlecenie banku lub operatora telekomunikacyjnego. Wówczas zastosowanie systemu ERP umożliwiłoby ewidencjonowanie prowizji od wpłat dłużników oraz rozliczenie kosztów operacyjnych. W obu przytoczonych przypadkach oraz w sytuacji połączenia w podmiocie windykacyjnym modelu usługowego windykacji z windykacją zakupionych pakietów wiarytelności system klasy ERP wykorzystywany jest do opracowywania raportów, w tym o charakterze finansowym. Łączenie na bieżąco danych pochodzących z procesu windykacji wiarytelności z danymi o pakietach wiarytelności w systemie klasy ERP daje możliwość

prowadzenia ewidencji, generowania raportów zarządczych albo wykorzystywanych w procesie podejmowania decyzji. Wykorzystanie systemów ERP w autorskich rozwiązaniach IT wspierających proces windykacji przekłada się na możliwość przygotowywania prognoz spłacalności oraz planowania obciążenia poszczególnych działów. W konsekwencji ułatwia to również szacowanie potencjału obsługi nowych lub dodatkowych pakietów wierzytelności. Daje się zauważyć, że obecnie wiele dostępnych na rynku systemów klasy ERP, wykorzystywanych przez relatywnie duże podmioty gospodarcze, posiada już wbudowany moduł windykacji. Przykładem na krajowym rynku mogą być Comarch ERP Optima (Comarch 2024) lub globalnie SAP Collections Management (Krzemiński 2022). Integracja modułów wsparcia windykacji w systemach klasy ERP umożliwia prowadzenie w przedsiębiorstwie monitoringu przeterminowanych należności. Stan taki, np. w przypadku podmiotów niewindykacyjnych, umożliwia prowadzenie przez te podmioty działań o charakterze prewencyjnym we własnym zakresie, zanim wierzytelności zostaną sprzedane lub zlecona zostanie ich windykacja przez zewnętrzny, wyspecjalizowany podmiot. Podsumowując, należy stwierdzić, że w podmiotach windykacyjnych systemy ERP są kluczowym narzędziem do zarządzania. Umożliwiają konsolidację danych z procesu windykacji z innymi danymi biznesowymi, co zapewnia spójność informacji finansowych i operacyjnych. Jest to szczególnie ważne przy windykacji masowej do raportowania i rozliczeń z klientami. Ten ostatni aspekt zyskuje na ważności w przypadku prowadzenia windykacji w modelu usługowym. Użycie systemów ERP w podmiocie windykacyjnym ułatwia kontrolę nad rentownością podejmowanych działań windykacyjnych z podziałem na pakiety wierzytelności lub grupy wierzytelności, wydzielone według przyjętych kryteriów, np. rodzaju wierzytelności.

Bieżąca analiza efektów windykacji, rozumianych jako analiza przychodów zrealizowanych na poszczególnych etapach windykacji w relacji do kosztów prowadzenia działań, umożliwia badanie efektywności nie tylko poszczególnych działów w podmiocie windykacyjnym, ale również efektywności realizowanej na poszczególnych etapach procesu windykacji wierzytelności masowych.

Systemy BPM stanowią element informatycznych systemów zarządzania, wpisując się w koncepcję procesów biznesowych. Systemy te wykorzystywane są do realizacji różnych funkcji, z których najważniejsze to modelowanie, automatyzacja, monitorowanie oraz usprawnianie procesów biznesowych. Niekiedy systemy BPM przedstawiane są jako silniki *workflow* (Bartlett i in. 2023) i to podejście doskonale wskazuje na ich zastosowanie do obsługi wierzytelności masowych w podmiocie windykacyjnym. Umożliwia to zamodelowanie działań podejmowanych na każdym z etapów procesu windykacji, łącznie ze wskazaniem alternatywnych ścieżek postępowania. Bazując na systemach BPM w windykacji, zamodelować można proces od wczesnych etapów, takich jak monitorowanie należności, przez procesy komunikacji z dłużnikiem na etapie windykacji polubownej, do procesów windykacji przymusowej.

Systemy BPM umożliwiają zaprojektowanie procesu windykacji jako sekwencji zdarzeń zależnych od czasu lub aktywności dłużnika. Zamodelowanie procesu dodatkowo ułatwia monitorowanie jego efektów finansowych, jak miało to miejsce w przypadku systemów klasy ERP albo według przyjętych w podmiocie windykacyjnym wskaźników KPI (*Key Performance Indicator*). Rozwiązanie to można rozszerzyć na sterowanie procesem, bazując na analizie realizowanych efektów procesu windykacji (Jankowski i Paliński 2024b). Rozważając wykorzystanie systemów BPM w podmiocie windykacyjnym, wskazać należy

na ich niewątpliwą zaletę, a mianowicie możliwość integracji z innymi systemami, w taki sposób, aby to BPM „pośredniczyło” pomiędzy CRM, ERP i DMS. Zakres wykorzystania systemów BPM nie zamyka się na modelowaniu procesów – pozyskane w trakcie ich funkcjonowania dane mogą zostać wykorzystane w procesie wyceny pakietów wierzytelności przed ich zakupem (Jankowski i Paliński 2024a). Modelowanie procesów, czy też w szerszym ujęciu zarządzanie procesami, ma kluczowe znaczenie w przypadku prowadzenia windykacji wierzytelności o charakterze masowym. Przy jego braku w podmiocie windykacyjnym należy się liczyć z ryzykiem prowadzenia nieefektywnego procesu, narażonego na liczne błędy będące konsekwencją prowadzenia działań na znacznej liczbie spraw. Zastosowanie systemów BPM wprowadza w funkcjonowanie podmiotów windykacyjnych standaryzację na etapie postępowania z wierzytelnościami oraz możliwość szybkiej adaptacji procesu do zmian np. będących wynikiem zmian regulacji prawnych. Systemy BPM podlegają ewolucyjnym zmianom w tzw. inteligentne systemy BPM.

Jednym z kluczowych obszarów funkcjonowania podmiotu windykacyjnego jest zarządzanie dokumentami. Właściwą realizację tego pozornie łatwego zadania umożliwiają systemy klasy DMS, przez zapewnienie podmiotom rozwiązań do bezpiecznego przechowywania i archiwizowania dokumentów. Posiadanie systemu DMS przez podmiot windykacyjny jest niemal koniecznością – wpływa on nie tylko na przebieg procesu windykacji, ale również przyczynia się do redukcji kosztów oraz czasu obsługi dokumentów. W podmiocie windykacyjnym zarządzanie dokumentami w formie papierowej jest zastępowane przez elektroniczny obieg dokumentów, właśnie dzięki wdrożeniu systemów DMS lub korzystaniu z platform typu ECM (*Enterprise Content Management*). Idea funkcjonowania systemów DMS zakłada, że dokumenty po ewentualnej digitalizacji, jeżeli były wcześniej dostępne jedynie w formie papierowej, trafiają do systemu. System DMS prowadzi ich indeksację na podstawie metadanych istotnych z punktu widzenia osoby prowadzącej proces. W przypadku podmiotów windykacyjnych indeksowanie prowadzone jest według:

- numeru sprawy w systemie, aby można było szybko identyfikować powiązania;
- identyfikatora dłużnika, aby można było łączyć wierzytelności na poziomie osoby dłużnika i w ten sposób prowadzić windykację wszystkich wierzytelności danego dłużnika jednocześnie;
- sygnatury akt, w przypadku skierowania roszczenia na drogę postępowania sądowego.

Podpinanie dokumentów pod kartotekę dłużnika lub pośrednio pod wierzytelności wraz z automatyczną analizą treści wykonywaną przez sztuczną inteligencję umożliwia pracownikom podmiotów windykacyjnych natychmiastowy wgląd w całość zgromadzonej dokumentacji dotyczącej sprawy lub dłużnika. Systemy DSM w windykacji są zazwyczaj integrowane z innymi systemami, co rozszerza ich pierwotne obszary zastosowań. Przykładem takich integracji może być dodanie do systemu DMS rozwiązań umożliwiających przeprowadzenie OCR (*Optical Character Recognition*) lub wykorzystanie NLP (*Natural Language Processing*) w celu interpretacji treści zawartych w przetwarzanych w podmiotach windykacyjnych dokumentach. Wykorzystanie NLP jest szczególnie użyteczne w odniesieniu do dokumentacji procesowej. Czytelnika zainteresowanego tematyką wykorzystania systemów DMS wspieranych przez sztuczną inteligencję odsyła się do rozdziału trzeciego.

2.3. Wpływ rozwoju sztucznej inteligencji na informatyczne systemy zarządzania w branży windykacyjnej

Bardzo szybki, wręcz wykładniczy rozwój sztucznej inteligencji (Kaplan i in. 2020), którego doświadczamy w ostatnich latach, nie mógł pozostać bez wpływu na informatyczne systemy zarządzania. Technologie sztucznej inteligencji dostarczają branży windykacyjnej nowych narzędzi i rozszerzeń funkcjonalności, a także opisanych wcześniej rozwiązań takich jak systemy klasy CRM, ERP, BPM i DMS. Rozszerzenia te wprowadzają nową jakość do analityki oraz automatyzacji działań podejmowanych w procesie windykacji wierzytelności o charakterze masowym. Wpływ rozwoju sztucznej inteligencji na systemy informatycznego zarządzania w windykacji warto rozpatrywać pod kątem takich aspektów, jak:

- zastosowanie uczenia maszynowego,
- przetwarzanie języka naturalnego,
- robotyzacja procesów.

Uczenie maszynowe, będące jedną z dynamicznie rozwijających się dziedzin sztucznej inteligencji, znajduje szerokie zastosowanie w sektorze zarządzania wierzytelnościami, szczególnie w obszarze windykacji wierzytelności masowej. Opiera się na budowie modeli analitycznych, które uczą się na podstawie danych i są zdolne do podejmowania decyzji lub generowania predykcji bez konieczności bezpośredniego programowania reguł decyzyjnych (Goodfellow i in. 2016). W praktyce windykacyjnej algorytmy ML wykorzystywane są do analizy danych historycznych o dłużnikach oraz portfelach wierzytelności, co pozwala na określanie prawdopodobieństwa spłaty, identyfikację grup ryzyka oraz dobór strategii windykacyjnych przypisanych do wydzielonych grup wierzytelności (Jankowski 2023).

Zastosowanie sztucznej inteligencji w tym zakresie istotnie ograniczyło wykorzystywane w przeszłości modele statystyczne, jak np. regresja logistyczna. Badania empiryczne dowodzą przewagi algorytmów ML, w tym lasów losowych, gradient boostingu oraz głębokich sieci neuronowych, w zakresie trafności opracowywanych prognoz (Bharath i Shumway 2008). Modele te mogą identyfikować złożone, nieliniowe relacje między zmiennymi, co czyni je skutecznymi narzędziami nie tylko w ocenie pojedynczych wierzytelności, lecz również w analizie całych portfeli wierzytelności. Zastosowanie ML nie ogranicza się wyłącznie do modelowania procesu windykacji wierzytelności masowych, może być również użyteczne do tworzenia modeli wycen pakietów wierzytelności na etapie ich zakupu.

W opracowaniach dotyczących zarządzania podmiotem windykacyjnym (Jankowski 2023) przedstawia się koncepcję budowy zintegrowanego modelu zarządzania wierzytelnościami masowymi, opartego na połączeniu wiedzy eksperckiej z wiedzą uzyskaną z eksploracji danych za pomocą uczenia maszynowego. Autor zastosował m.in. drzewa decyzyjne do analizy zbiorów danych liczących ponad 880 tysięcy rekordów wierzytelności, pochodzących z działających na rynku podmiotów windykacyjnych. Celem projektu było zbudowanie bazy reguł decyzyjnych wspierających proces windykacji wierzytelności masowych w modelowym podmiocie windykacyjnym, co doprowadziło do powstania hybrydowego modelu, który łączy podejścia jakościowe z ilościowym, a jego struktura umożliwia adaptację do różnych

warunków organizacyjnych. Wykorzystanie w tym przypadku uczenia maszynowego lub ogólnie sztucznej inteligencji polegało na odkrywaniu wiedzy w danych historycznych. Zapisana pod postacią bazy reguł odkryta wiedza może zostać wykorzystana w informatycznych systemach zarządzania do sterowania procesem windykacji wierzytelności masowych na każdym z etapów obsługiwanych przez podmiot windykacyjny.

Zastosowanie ML obejmuje także automatyzację scoringu wierzytelności, czyli przypisywanie punktacji ryzyka nowym sprawom na podstawie ich cech charakterystycznych. Modele predykcyjne mogą wskazać, że dług o określonych parametrach ma np. 80% szans na spłatę w ciągu np. 90 dni od pierwszego kontaktu z dłużnikiem. Takie informacje pozwalają na lepsze zarządzanie zasobami w systemach ERP. Sprawy oszacowane jako sprawy wysokiego ryzyka są szybciej kierowane na drogę postępowania sądowego (etap windykacji przymusowej), natomiast te z dużym potencjałem odzysku bez zaangażowania mechanizmów przymusu prawnego objęte są wydłużonymi działaniami na etapie windykacji polubownej. Innym, równie ważnym zastosowaniem ML jest segmentacja behawioralna dłużników, czyli grupowanie ich według wzorców zachowań. Modele mogą wydzielić grupy dłużników, co daje możliwość użycia różnych strategii windykacyjnych w systemach BPM w taki sposób, aby np. w grupie dłużników notorycznie ignorujących kontakt z podmiotem windykacyjnym eskalować działania podejmowane w procesie windykacji. Takie podejście, określane jako *intelligent debt collection*, umożliwia podmiotom windykacyjnym profilowanie komunikacji z dłużnikiem. ML znajduje także zastosowanie w planowaniu finansowym i wycenie portfeli wierzytelności, co jest szczególnie istotne dla funduszy sekurytyzacyjnych i inwestorów. Modele przewidujące spłaty umożliwiają szacowanie przyszłych przepływów pieniężnych, a tym samym bardziej precyzyjną wycenę pakietów wierzytelności i ocenę ryzyka inwestycyjnego. To z kolei przyczynia się do wzrostu rentowności inwestycji w wierzytelności i umożliwia lepsze zarządzanie kapitałem. W badaniach (Jankowski 2023) wykazano, że uczenie maszynowe może służyć nie tylko do tworzenia nowych reguł decyzyjnych, ale także jako narzędzie weryfikacji i kalibracji wiedzy eksperckiej. Modele ML potrafią potwierdzić skuteczność dotychczas stosowanych strategii windykacyjnych lub ujawnić nieefektywności wynikające z intuicyjnych i niezaweryfikowanych założeń. Proponowany przez autora model zarządzania został dodatkowo zaimplementowany w notacji BPMN, co umożliwia jego bezpośrednią integrację z systemami klasy CRM i ERP.

Uczenie maszynowe rozszerza funkcjonalnie informatyczne systemy zarządzania, wprowadzając do systemów windykacyjnych warstwę inteligencji decyzyjnej – od scoringu i segmentacji klientów, przez prognozowanie spłat i wyceny portfeli, aż po automatyzację działań operacyjnych.

Przetwarzanie języka naturalnego oraz sztuczna inteligencja konwersacyjna odgrywają znaczącą rolę w cyfrowej transformacji procesów windykacyjnych, wprowadzając zmiany jakościowe w całym procesie. Wykorzystanie mechanizmów NLP w systemach zarządzania pozwala z jednej strony na interpretację pism procesowych i ich obsługę w systemach DMS oraz CMS, a z drugiej zaś – na generowanie komunikatów słownych, co ma szerokie zastosowanie w wielokanałowej komunikacji z dłużnikiem (Erhardt 2025). Dzięki temu możliwe jest w pełni zautomatyzowane prowadzenie windykacji niskokwotowych wierzytelności bez udziału człowieka. Kolejnym zastosowaniem NLP w windykacji jest automatyczna

klasyfikacja treści korespondencji przychodzącej od dłużników oraz – w połączeniu z systemami CRM oraz ERP – przygotowywanie pism oraz powiadomień (np. SMS) kierowanych do dłużnika na poszczególnych etapach procesu windykacji. Nowoczesne systemy AI, bazujące na generatywnych modelach językowych, potrafią nie tylko sklasyfikować wiadomość, ale też wygenerować adekwatną odpowiedź, łącząc dane przechowywane w bazach podmiotu windykacyjnego z treścią wniosku/pisma otrzymanego od dłużnika – mogą np. przygotować ugodę i harmonogram spłat jako odpowiedź na pisemną lub ustną prośbę dłużnika o rozłożenie zobowiązania na raty. Tego typu automatyzacja pozwala podmiotom windykacyjnym skracać czas reagowania na zgłoszenia, angażując pracowników tylko do obsługi spraw spornych (Kondracki 2023).

W przypadku komunikacji pisemnej NLP pozwala kontrolować, czy w pismach zostały zawarte obowiązkowe informacje prawne (Kondracki 2023) lub czy są zgodne z szablonami zatwierdzonymi do użycia przez klienta (w przypadku prowadzenia windykacji w modelu usługowym) lub w imieniu klienta (np. banku). Integracja elementów sztucznej inteligencji z informatycznymi systemami zarządzania, poza poprawą ich skalowalności, pozwala również na ich wysoką dostępność, co umożliwi realizację działań windykacyjnych w czasie dogodnym dla dłużnika. Zmianom na skutek zastosowania NLP podlegają również procesy oceny konsultantów/windykatorów – odsłuchiwanie i ocena rozmów przez przełożonych lub wyznaczonych pracowników są zastępowane automatycznym monitoringiem rozmów z dłużnikami. Systemy tego typu, dokonując transkrypcji rozmów telefonicznych i prowadząc analizę użytego języka oraz tonu emocjonalnego, umożliwiają nie tylko ocenę pracownika na potrzeby np. systemów premiowych, ale również detekcję naruszeń skryptów rozmów lub niezgodności z procedurami przyjętymi w podmiocie windykacyjnym.

Zastosowanie NLP w procesie windykacji jest możliwe również w modelach rekomendujących strategię windykacyjną na podstawie analizy sentymentu (prowadzonej on-line w trakcie rozmowy konsultanta z dłużnikiem).

Podsumowując, należy stwierdzić, że NLP i AI wykorzystywane w celach konwersacyjnych pozwalają podmiotom windykacyjnym automatyzować i personalizować proces windykacji, co przekłada się na: skrócenie czasu reakcji, podniesienie jakości komunikacji oraz skalowalność działań bez konieczności zwiększania zatrudnienia w sposób istotny. Rola sztucznej inteligencji wykorzystanej na potrzeby podmiotów windykacyjnych będzie rosła wraz z dalszym rozwojem modeli językowych oraz integracją z systemami CRM, DMS i BPM.

2.4. Przyszłość windykacji masowej: automatyzacja, dane i decyzje oparte na AI

Ewolucja informatycznych systemów zarządzania w branży windykacyjnej obrazuje transformację cyfrową zachodzącą w sektorze zarządzania wierzytelnościami o charakterze masowym. Tradycyjnie wykorzystywane w branży windykacyjnej systemy klasy CRM, ERP, BPM i DMS ewoluowały z funkcji wspierających działania operacyjne do pełnoprawnych platform decyzyjnych. Aktualnie w wyniku rozszerzenia zakresu funkcjonalności następuje ścisła integracja z algorytmami uczenia maszynowego (ML), przetwarzaniem języka

naturalnego (NLP) oraz systemami konwersacyjnymi AI, co otwiera nowe, dotychczas niedostępne możliwości automatyzacji procesów windykacyjnych, jak i zarządzania relacjami z różnymi grupami interesariuszy. Systemy CRM, w połączeniu z AI, stają się obecnie narzędziami umożliwiającymi rejestrację i analizę interakcji z dłużnikiem oraz personalizację podejmowanych działań, dzięki czemu negocjacje z dłużnikiem mogą być dostosowane do jego profilu i zachowań, co przekłada się na wyższą skuteczność podejmowanych w procesie windykacji działań. Z kolei ERP zapewnia pełną integrację danych finansowych i operacyjnych, umożliwiając dynamiczne monitorowanie efektywności portfeli wierzytelności oraz wspomaganie decyzji zarządczych opartych na rzeczywistych przepływach finansowych. Systemy klasy BPM zyskują nową rolę jako narzędzia do projektowania adaptacyjnych, warunkowych scenariuszy windykacyjnych, automatyzujących działania na każdym etapie procesu – od negocjacji z dłużnikiem na etapie polubownym po działania wykorzystujące przymus prawny na etapach windykacji sądowej i komorniczej.

Osią zmian w podejściu do informatycznych systemów zarządzania jest implementacja w nich elementów uczenia maszynowego, które wspierają proces decyzyjny dzięki automatyzacji scoringu spraw, predykcji spłat, segmentacji behawioralnej dłużników oraz doborowi optymalnych ścieżek postępowania w procesie windykacji. Dzięki analizie dużych zbiorów danych możliwe jest generowanie reguł decyzyjnych o skuteczności wyższej niż w przypadku klasycznych metod eksperckich, a cały proces windykacyjny może być dzięki temu w pełni zautomatyzowany i usprawniany w sposób ciągły, np. po zakończeniu windykacji kolejnego pakietu wierzytelności masowych. Na szczególną uwagę zasługuje rola przetwarzania języka naturalnego (NLP) oraz tzw. AI konwersacyjnej, które istotnie zmieniają sposób prowadzenia komunikacji z dłużnikiem w procesie windykacji, wprowadzając zmianę o charakterze jakościowym. NLP pozwala automatyzować klasyfikację przychodzącej korespondencji, generować odpowiedzi na standardowe zapytania, analizować treść rozmów i dokumentów, w tym procesowych, a także wspierać monitoring jakości windykacji/negocjacji z dłużnikiem.

Analiza zastosowania ISZ w windykacji pokazuje, że informatyzacja procesów nie jest już tylko wsparciem operacyjnym, lecz także warunkiem koniecznym do utrzymania efektywności i konkurencyjności w środowisku o dużej zmienności danych i skali działania. Dzięki sztucznej inteligencji systemy windykacyjne mogą przejąć znaczną część decyzji operacyjnych i komunikacyjnych, a także w sposób ciągły adaptować się do nowych informacji lub nowej wiedzy odkrytej w zbiorach danych historycznych. Ponadto integracja systemów ISZ z dużymi modelami językowymi, technologią OCR, analizą predykcyjną i robotyzacją procesów wskazuje kierunek dalszego rozwoju branży windykacyjnej. Windykacja masowa, dzięki połączeniu danych, algorytmów i procesów cyfrowych, może stać się bardziej efektywna kosztowo, mniej obciążająca dla zasobów ludzkich, a jednocześnie bardziej spersonalizowana i zgodna z oczekiwaniami dłużników. Zatem dalszy rozwój systemów zarządzania wierzytelnościami będzie nierozdzielnie związany z postępującą cyfryzacją, integracją danych oraz wdrażaniem inteligentnych algorytmów decyzyjnych, które umożliwią automatyzację działań oraz ich ciągłą adaptację.

3. Wykorzystanie technologii AI w zarządzaniu pismami procesowymi

3.1. Rola etapu postępowania w strukturze dokumentacyjnej

Model biznesowy firm windykacyjnych można określić w zależności od etapu, na którym przejmują one wierzytelności do obsługi. W takim przypadku rysuje się podział na spółki windykacyjne nabywające wierzytelności nieprzeterminowane oraz te, które nabywają wierzytelności przeterminowane (Mikutowski 2024). W pierwszym przypadku działalność sekurytyzacyjna polegać będzie na nabywaniu portfeli na rachunek własny. Działania windykacyjne skoncentrowane będą na monitorowaniu braku terminowej spłaty, wywołującym podjęcie czynności windykacyjnych. W przypadku zakupu wierzytelności przeterminowanych z procesu eliminuje się monitoring spłat, przechodząc od razu do jednego z etapów windykacji. Wybór etapów windykacji wynikał będzie zarówno ze stanu prawnego, jak i już podjętych przez wierzyciela pierwotnego działań windykacyjnych.

W ujęciu ogólnym proces windykacji portfeli wierzytelności przebiega zgodnie z trzystopniowym modelem, który dzieli cały przebieg działań na trzy etapy: windykację polubowną, windykację sądową oraz windykację komorniczą (Jurkiewicz 2013). Na etapie windykacji polubownej, nazywanej również przedsądową, podejmowane działania ukierunkowane są na znalezienie porozumienia z dłużnikiem bez angażowania sądu. Podejmowane na tym etapie czynności zmierzają np. do podpisania ugody lub spłaty zobowiązania w ratach. Etap ten przebiega bez określonych pod względem formalnym reguł. Kolejne dwa etapy: windykacja sądowa oraz windykacja komornicza (nazywana również egzekucyjną), wykorzystują mechanizmy prawne. Podejmowane na tych etapach działania wprowadzają formalne postępowanie w celu uzyskania nakazu zapłaty (etap windykacji sądowej), a następnie przeprowadzenie działań przez komornika w celu wyegzekwowania należności. Na tych dwóch etapach windykacji portfeli wierzytelności powstaje większość dokumentacji. Liczba powstałych dokumentów pośrednio przekłada się na kosztochłonność etapów oraz czasochłonność podejmowanych działań, co stwarza możliwość stosowania szeroko rozumianej automatyzacji w obsłudze pism m.in. o charakterze procesowym. Z praktyki biznesowej wynika, że na etapie windykacji polubownej generowane jest od jednego pisma do trzech pism na każdą sprawę (np. monit, wezwanie do zapłaty, propozycja ugody) (Wilk-Nawrot 2024), zaś na etapach windykacji sądowej i komorniczej od siedmiu do trzynastu pism (np. pozew, nakaz zapłaty, sprzeciw,

wniosek o wszczęcie egzekucji, wniosek o zajęcie majątku, zawiadomienie o czynnościach komorniczych) (RESPO 2024).

Relatywnie duży odsetek pism powstających na etapach windykacji sądowej i komorniczej w stosunku do całkowitej liczby dokumentów tworzonych w ramach procesu windykacyjnego sugeruje zasadność poszukiwania oszczędności poprzez automatyzację oraz zastosowanie rozwiązań wykorzystujących sztuczną inteligencję. W poniższym rozdziale, ze względu na zakres tematyczny, uwaga skoncentrowana będzie na docelowym zastosowaniu sztucznej inteligencji do analizy treści pism korespondencji otrzymywanej z sądu, w celu odpowiedniego odnotowania w systemie obsługi wierzytelności oraz sterowania (podejmowania decyzji) w procesie windykacji.

3.2. Przebieg procesu – rys historyczny

Tradycyjne podejście do obsługi pism, w tym pism o charakterze procesowym, w spółkach windykacyjnych opierało się głównie na pracy ludzkiej, wspomaganej przez narzędzia biurowe. Nie tylko samo tworzenie pozwów, generowanie wezwań do zapłaty czy też przygotowywanie odpowiedzi na pisma realizowane było manualnie lub z wykorzystaniem prostych mechanizmów automatyzujących, takich jak szablony pism czy korespondencja seryjna. Niejednokrotnie pracownicy wprowadzali do pism procesowych dane w sposób ręczny, podobnie przebiegał również proces przygotowywania załączników. Taki sposób postępowania nie tylko skutkował wysoką liczbą błędów, lecz również znacząco zwiększał koszty całego procesu. Przyczyn częstych pomyłek należy upatrywać w dużej liczbie pism przygotowywanych przez jednego pracownika w ramach monotonnych, powtarzalnych czynności. W podobny sposób zorganizowana była obsługa przychodzących pism procesowych, z których każde było analizowane przez zespół prawny w celu uzupełnienia odpowiednich pól w systemie obsługi wierzytelności poprzez odnotowanie istotnych zdarzeń. Wiele czynności było wykonywanych przez duży zespół aplikantów radcowskich. Taki przebieg procesu windykacji dotyczy oczywiście dużego podmiotu windykacyjnego, obsługującego wierzytelności masowe wynikające np. ze świadczenia usług telekomunikacyjnych oraz sprzedaży usług o charakterze bankowym (np. udzielonych, a nie spłacanych kredytów).

Tak prowadzone działania usprawniane były zarówno na poziomie organizacyjnym, jak i rozwiązań IT. Usprawnienie organizacyjne polegało na podzieleniu przychodzących pism na dwie grupy, którymi zajmowały się dwa zespoły pracowników Zespół pierwszy, składający się z pracowników biurowych, przenosił z pism informacje identyfikujące (np. sygnaturę), informacje dotyczące części opisowej ujawnionych zdarzeń, np. korekt kwoty czy zmiany danych dłużnika, do systemu elektronicznego wspomagającego prowadzenie działań windykacyjnych. Zadaniem zespołu drugiego, składającego się z pracowników działu prawnego, była analiza merytoryczna pism procesowych. Zmniejszenie liczby aplikantów i przekazanie części zadań tańszym pracownikom pozwoliło obniżyć koszty o około 20% w porównaniu z analizą wszystkich pism tylko przez dział prawny. Usprawnienia, wdrażane razem z rozwojem narzędzi IT, dotyczyły zarówno przygotowywania korespondencji wychodzącej w sposób masowy z użyciem szablonów, jak i sposobów obsługi pism przychodzących.

W większości spółek windykacyjnych wdrożone usprawnienia miały zbliżony charakter i polegały na zastąpieniu tradycyjnej, papierowej obsługi korespondencji systemem elektronicznym, co umożliwiło wprowadzenie elektronicznego obiegu dokumentów. Przejście z dokumentacji papierowej na system elektronicznego obiegu dokumentów zapewniał sekretariat lub w bardziej rozbudowanych strukturach dział mass mailingu. Podejmowane działania obejmowały skanowanie pism przychodzących oraz podpinanie skanu pod obsługiwaną sprawę w systemie wsparcia windykacji. Pisma były najczęściej identyfikowane na podstawie danych dłużnika, a następnie trafiały do dwóch wcześniej wspomnianych zespołów w celu dalszej analizy i przetworzenia. Skalowalność działań windykacyjnych była istotnie ograniczona ze względu na konieczność proporcjonalnego zwiększania zatrudnienia wraz ze wzrostem liczby obsługiwanych wierzytelności. Kolejnym etapem rozwoju, jaki odnotowano w podmiotach windykacyjnych, była automatyczna analiza zawartości pism procesowych w obszarze wybranych, łatwo identyfikowalnych cech (pól pisma procesowego). Działania te obejmowały, oprócz skanowania, również wykonanie optycznego rozpoznania znaków (OCR, *Optical Character Recognition*).

Posiadanie nie tylko skanu pisma, ale również wersji tekstowej nadającej się do automatycznej analizy, prowadziło w naturalny sposób do zmiany podejścia. Usprawnia bazowały na wykorzystaniu wyrażeń regularnych, służących do wyszukiwania, dopasowania oraz walidacji tekstu według przyjętych wzorców. Dzięki temu możliwe stało się przyspieszenie pracy związanej nie tylko z podpinaniem pism procesowych pod kartotekę dłużnika, ale również z automatycznym uzupełnianiem pól o charakterze deskryptywnym w systemie wsparcia windykacji, np. adresów e-mail, numerów PESEL, zmiany danych na format odpowiedni dla danego systemu wsparcia windykacji (np. automatyczna zmiana formatu daty z DD-MM-RRRR na RRRR-MM-DD). Działania te przekładały się zarówno na redukcję kosztów zatrudnienia pracowników biurowych, jak i eliminację błędów popełnianych w trakcie ręcznego przenoszenia informacji z pism papierowych.

Kolejnym etapem usprawnień, które przy okazji niwelowały wady stosowania wyrażeń regularnych, było wykorzystanie eksploracji tekstu przy użyciu rozwiązań z wykorzystaniem uczenia maszynowego. Zastosowanie rozwiązań opartych na text-miningu umożliwiło bardziej elastyczną klasyfikację pism procesowych oraz wydobywanie z nich użytecznych informacji, przewyższając pod tym względem podejście oparte na wyrażeniach regularnych. Przełomem w zakresie obsługi pism procesowych dla branży windykacyjnej w Polsce było wprowadzenie Elektronicznego Postępowania Upominawczego. EPU, wprowadzone w 2010 roku jako odrębny tryb w postępowaniu cywilnym (Mendrek 2021), umożliwia zarówno składanie pozwu, jak i komunikację z e-sądem przy wykorzystaniu elektronicznego obiegu dokumentów. Szczególnie interesujące pod względem usprawnienia procesu wydaje się wykorzystanie plików XML oraz PDF. Zawarte w nich atrybuty umożliwiają mapowanie na stosowne pola w bazach danych wykorzystywanych przez systemy wsparcia windykacji w spółkach windykacyjnych. Rozwiązanie to nie eliminuje jednak kluczowego problemu, jakim jest analiza merytoryczna pism procesowych, wykonywana przez pracowników. Dodatkowo usprawnienia osiągnięte przy zastosowaniu EPU nie mają zastosowania w przypadku postępowań przez Sądem Właściwości Ogólnej (SWO), bez względu na to, w jakim trybie obsługiwany jest złożony pozew.

Rozwój sztucznej inteligencji otwiera przed spółkami windykacyjnymi nowe możliwości w obszarze daleko idącej automatyzacji, zarówno po etapie przygotowania pozwów, przygotowania uzasadnień w sposób bardziej dopasowany do materiału dowodowego niż w przypadku stosowania szablonów, jak i w zakresie obsługi przychodzącej korespondencji sądowej. O ile obszary przenoszenia danych o charakterze identyfikującym lub metadane były już od dawna dobrze obsługiwane, to interpretacja części merytorycznej w dalszej części wymagała udziału pracownika działu prawnego. W zakresie poruszonym w tym rozdziale pozostaje wyłącznie część przychodzącej korespondencji dotyczącej windykacji sądowej oraz komorniczej, zaś realizacja stawianego zadania, jakim jest prototyp systemu do obsługi pism procesowych, wymagał będzie takiego doboru narzędzi, dzięki któremu będzie możliwe usprawnienie procesu i niedopuszczenie do sytuacji ujawnienia danych dłużników. AI dobrze radzi sobie z generowaniem i weryfikacją dokumentów, to interpretacja informacji zwrotnych pozostaje wyzwaniem, które ma rozwiązać opracowywany prototyp.

Zaprezentowany przebieg procesu zarządzania korespondencją ilustruje etapy zmian, jakie zaszły w podejściu do obsługi pism, w tym procesowych, w spółkach windykacyjnych. Nie oznacza to jednak, że każda z tych spółek przeszła przez cały proces w identyczny sposób lub w takim samym zakresie. Zakres i tempo zmian były uzależnione od dostępnych rozwiązań IT, przyjętego modelu biznesowego, możliwości finansowych, zasobów kadrowych oraz sposobu ich pozyskiwania

3.3. Zastosowanie AI/ML w zarządzaniu pismami procesowymi

Stosowanie rozwiązań automatyzujących związanych z wdrożeniem AI bez wątpienia przekłada się na wymierne korzyści ekonomiczne oraz te osiąmane po stronie operacyjnej w spółkach windykacyjnych. Po krótko wymienić można takie obszary, jak: oszczędność czasu niektórych czynności przygotowawczych, redukcja kosztów operacyjnych w wyniku automatyzacji rutynowych działań czy automatycznego sprawdzania poprawności. Korzystne efekty zastosowania AI w windykacji nie kończą się wyłącznie na procesie obsługi korespondencji, ale również przekładają się na poziom ściągalności należności, chociażby dzięki zastosowaniu mechanizmów uczenia maszynowego pod kątem doboru strategii windykacyjnych (Jankowski i Paliński 2024b).

Zalety wdrożenia elementów sztucznej inteligencji w spółce windykacyjnej, oprócz wymienionych, przekładają się również na zwiększenie możliwości skalowalności biznesu w wyniku obsługi liczniejszych portfeli wierzytelności bez uszczerbku dla procesu windykacji czy bez konieczności powiększania zespołów obsługujących etapy windykacji sądowej oraz komorniczej.

Wykorzystanie sztucznej inteligencji w obsłudze pism procesowych nie tylko obejmuje nowe obszary wymagające zrozumienia merytorycznej części dokumentacji, ale również umożliwia poprawę dotychczas wykorzystywanych rozwiązań, np. OCR wspomagany przez AI o wiele lepiej radzi sobie z rozpoznaniem tekstu z dokumentów nieczytelnych, o niskiej jakości skanowania czy notatek wykonanych odręcznie, niż klasyczny komponent OCR.

Wdrożenie rozwiązań AI w procesie obsługi pism procesowych może przebiegać etapami, w ramach których realizowane są poszczególne zadania. Przykładowy przebieg obsługi pism procesowych, wspomaganych na każdym etapie przez sztuczną inteligencję, zaprezentowano na rysunku 3.1.



Rys. 3.1. Przykładowy proces wdrożenia AI w obsłudze pism procesowych

Zadania stawiane przed każdym z wydzielonych etapów przedstawiono poniżej, wskazując jednocześnie rozwiązania techniczne, które mogą zostać wykorzystane do realizacji.

Moduł OCR wspierany AI – odpowiadający za rozpoznanie tekstu na podstawie skanu dokumentu lub jego zdjęcia. Celem modułu jest konwersja treści z formatu graficznego na tekstowy. Efektem działania modułu jest przygotowanie tekstowej postaci danych w celu ich dalszej analizy. Zamienny podany format XML w nazwie modułu wskazuje na zastosowanie już gotowych plików, pobranych np. w usłudze e-sąd lub będących efektem wykorzystania EPU. W procesie OCR wspomagane przez AI wykorzystane mogą zostać wyspecjalizowane sieci neuronowe. Produktem finalnym modułu (a docelowo agenta OCR) jest tekst przygotowany do procesu ekstrakcji informacji (Kulkarni 2024). Przykładem gotowego rozwiązania, oprócz sieci neuronowych, umożliwiające przeprowadzenie OCR jest Tesseract lub eIDoc. Współczesne rozwiązania wykorzystujące np. modele konwolucyjne do rozpoznania kształtów znaków i struktur dokumentów umożliwiają identyfikację tabelarycznych zestawień, podpisów odręcznych czy stempli (Alphamoon 2023).

Moduł klasyfikacji dokumentu na podstawie tekstu oraz metadanych otrzymanych z modułu OCR przeprowadza klasyfikację pisma procesowego do jednej z grup, identyfikując pismo jako: odpowiedź na pozew, nakaz zapłaty, wyrok, apelacja, wniosek dowodowy. Z uwagi na specyficzny charakter pism procesowych, użycie żargonu czy określonych sformułowań klasyfikacja staje się zadaniem nietrywialnym. Klasyfikacja wykonywana jest z wykorzystaniem metod przetwarzania języka naturalnego (NLP). Wykorzystanie NLP umożliwia rozpoznanie nawet pism nieoznaczonych, jedynie na podstawie ich treści. Z uwagi na obszar zastosowania wskazane jest użycie modeli uczonych na języku prawniczym, a konkretnie na modelach dostosowanych do polskiego języka prawniczego. W tym obszarze obiecujące efekty przynosi wykorzystanie zarówno konwolucyjnych (CNN, *Convolutional Neural Networks*), jak i rekurencyjnych (RNN, *Recurrent Neural Network*) sieci neuronowych. Przykład aplikacji oraz ocenę poziomów klasyfikacji przeprowadzonych na polskich orzeczeniach sądowych znaleźć można m.in. w pracy Kostrzewy i Nowaka (2022). Wykorzystanie gotowych rozwiązań może obejmować implementację językowych modeli transformerowych, takich jak BERT (*Bidirectional Encoder Representations from Transformers*) lub jego wariant Legal BERT – w szczególności polskich odmian – w celu lepszego uchwycenia niuansów polskiego języka prawniczego, co przekłada się na wyższą

jakość klasyfikacji. Ekstrakcja informacji może być realizowana także bez użycia sztucznej inteligencji, np. przy zastosowaniu wyrażeń regularnych lub metod text-miningu, jednak zastosowanie AI wprowadza nową jakość na tym etapie obsługi pism o charakterze procesowym. Po klasyfikacji na dokumentach przeprowadza się wydobywanie z tekstu kluczowych danych oraz faktów, np. dane stron, rodzaj i kwota roszczenia, naliczone odsetki czy numery identyfikujące umowę / sygnatury akt. Co bardziej interesujące, możliwe staje się również wydobywanie stwierdzeń wskazujących na przebieg działań, takich jak podniesienie zarzutu przedawnienia, zmiana danych adresowych, ugoda czy też informacje wskazujące np. na bezzasadność roszczenia (np. w przypadkach oszustwa). Moduł, a docelowo agent ekstrakcji danych, wykorzystuje tzw. rozpoznawanie jednostek nazwanych. Modele NER (*Named Entity Recognition*) kategoryzują encje do różnych predefiniowanych typów, które są kluczowe do zrozumienia zawartości pism procesowych.

Z uwagi na różne podejście do tworzenia systemów NER kluczowe jest dobranie rozwiązania adekwatnego do wdrażanego rozwiązania. Wybrane, typowe podejścia do tworzenia NER bazują na niżej wymienionych systemach (SHAIP 2025).

- Systemy oparte na słowniku – w tym przypadku system słownikowy w NER porównuje tekst z gotowym słownikiem terminów. Jest relatywnie prosty, ale wymaga częstych aktualizacji słownika, aby działać skutecznie.
- System oparty na regułach, w którym informację wydobywa się na podstawie wcześniej zdefiniowanych zestawach reguł. Wyróżniamy dwa zestawy: reguły wzorcowe (oparte na układzie wyrazów) lub reguły kontekstowe (zależne od znaczenia i otoczenia poszczególnych wyrazów).
- Systemy bazujące na uczeniu maszynowym wykorzystują w działaniu modele statystyczne i cechy tekstu do rozpoznawania encji. Cechują się wyższą elastycznością niż podejścia słownikowe lub regułowe. Efektem ich działania jest możliwość identyfikacji encji pomimo różnic w zapisie.
- Systemy oparte na głębokim uczeniu wykorzystują sieci neuronowe do wykrywania złożonych wzorców w tekście. Niestety rozwiązanie to, pomimo wielu zalet, wymaga dużych zasobów obliczeniowych. Na potrzeby faktycznego wdrożenia zalecane jest stosowanie modelu hybrydowego do tworzenia NER, łączącego reguły, statystykę i uczenie maszynowe. Efektem działania modułu są zbiory informacji, które mogą podlegać dalszej analizie lub być użyte wyłącznie do aktualizacji stanu wiedzy (bazy danych) na poziomie kartoteki dłużnika (informacji o wiaryznościach) w systemie wspomaganie windykacji wiaryzności. Efektem ekstrakcji informacji z danych jest zatem ustrukturyzowany zestaw informacji z pisma, np. w formacie JSON, XML lub, jak wspomniano, jako zapis w bazie danych. Przykładem gotowego rozwiązania dostosowanego do języka polskiego jest projekt PolDeepNer2 (PolDeepNer2, 2022).
- Moduł porównywania treści ma zadanie czysto techniczne, jednak istotne z uwagi na proces prowadzenia windykacji. W ramach modułu dokonywane jest porównanie aktualnie analizowanego pisma z dokumentami historycznymi (wcześniejszymi pismami w danej sprawie). Działanie takie podejmowane jest w celu wykrycia sprzeczności lub ujawnienia nowych twierdzeń / faktów nieodnotowanych w systemie wsparcia windykacji.

- Analiza intencji stanowi najciekawszy obszar zainteresowania. Efektem działania modułu jest określenie celu oraz intencji zawartej w części opisowej dokumentacji. W efekcie odejmowanych w module działań jest określenie powodów podjętych decyzji, oczekiwań stron, formalnych żądań lub faktów determinujących dalsze czynności. W tradycyjnych modelach obsługi pism procesowych czynności te były realizowane przez pracowników działu prawnego, ze względu na konieczność rozumienia nie tylko treści, ale również kontekstu prawnego. Zastosowanie w tym obszarze rozwiązań sztucznej inteligencji wymaga nowoczesnych modeli NLP lub ogólnie dużych modeli językowych, dających możliwość „rozumienia” tej części pism procesowych. Moduł ten podlega daleko idącej kontroli z uwagi na konsekwencje dla procesu windykacji podjętych błędnych decyzji lub istotne ryzyko prezentowania przez modele LLM (*Large Language Model*) na etapie analizy treści pisma nieprawdziwych wniosków. W tym przypadku konieczne będzie zastosowanie mechanizmów redukujących ryzyko tzw. halucynacji modelu językowego. Z gotowych rozwiązań mogących znaleźć zastosowanie wymienić można GPT-4, BERT czy PaLM2.
- Walidacja formalnoprawna – zadaniem modułu jest sprawdzanie, czy przygotowane pisma procesowe spełniają stawiane im wymogi formalne. Moduł ten może być wykorzystywany opcjonalnie, jednak ze względu na potrzebę szerokiego spojrzenia na zastosowanie sztucznej inteligencji w tym obszarze warto uwzględnić go w szablonie procesu obsługi dokumentów. W ramach modułu przewidziane jest nie tylko sprawdzenie zgodności z wymogami prawnymi, ale również weryfikacja kompletności oraz poprawności danych, oznaczenia stron, obecności załączników oraz sprawdzenie, czy przewidziane w regulacjach terminy są zachowane. Efektem działań podejmowanych w module jest wskazanie uchybień oraz wstrzymanie dalszego przetwarzania pism w przypadku wykrycia odstępstw od przyjętych reguł.
- Komunikacja / mapowanie zdarzenia – drugim po module porównywania treści jest moduł o charakterze narzędziowym. Istnienie modułu zapewnia komunikację pomiędzy systemem obsługi pism procesowych a systemem wsparcia windykacji funkcjonującym w konkretnej spółce. W ramach modułu, a docelowo agenta, podejmowane są czynności mające na celu uzupełnienie danych w systemie wsparcia windykacji.

Nowoczesne, oparte na AI rozwiązania wykorzystywane do obsługi pism procesowych funkcjonują w wielu obszarach (jak pokazano na rysunku 3.1). Wykorzystują technologie OCR i NLP do analizy i „zrozumienia” oraz algorytmy uczenia maszynowego zarówno do podejmowania decyzji w procesie windykacji, jak i generowania odpowiedzi na korespondencję formalną z sądu oraz działania podejmowane przez dłużnika.

Prowadząc badania literaturowe, napotkać można liczne przypadki wykorzystania AI w branży windykacyjnej, nieograniczające się do przetwarzania dokumentów, choć to właśnie ten obszar funkcjonowania firmy daje ogromny potencjał do automatyzacji. Do ciekawszych zastosowań uczenia maszynowego czy też sztucznej inteligencji należą sterowanie procesem windykacji wierzitelności masowych za pomocą dobranych reguł postępowania (Jankowski i Paliński 2024b) czy automatyczne kontrole zgodności z obowiązującymi regulacjami, zarówno na gruncie prawa, jak i wewnętrznych procedur danego przedsiębiorstwa. Przekazywanie do publicznej wiadomości informacji o udanych wdrożeniach sztucznej inteligencji coraz częściej stanowi jedno z narzędzi marketingowych. Działania takie ukierunkowane są na

budowę wizerunku podkreślającego podążanie za trendami oraz stosowanie nowoczesnych rozwiązań z rodziny IT w praktyce biznesowej. W sieci można znaleźć informację o wdrożeniu przez Alphamoon.ai w serwisie KRUK S.A. innowacyjnego rozwiązania bazującego na IDP (*Intelligent Document Processing*). Umożliwia ono wykorzystanie dokumentacji windykacyjnej jako cennego źródła danych o osobach zadłużonych. Wdrożone rozwiązanie umożliwia automatyczne wyszukiwanie informacji w różnorodnych dokumentach wykorzystywanych przez różne działy, takie jak skip tracing czy kancelaria prawna.

Kluczowym celem wdrożenia było zautomatyzowane, zgodne z procedurami i prawem pozyskiwanie informacji niezbędnych do skutecznego prowadzenia działań windykacyjnych. W materiałach informacyjnych (Alphamoon 2024) wskazuje się, że zastosowanie IDP automatyzuje najbardziej czasochłonne procesy od ekstrakcji danych po kontakt z dłużnikiem. AI wspiera analizę dokumentów, automatyzuje płatności i umożliwia szybsze wzbogacanie danych o dłużnikach (skip tracing), co przyczynia się do redukcji wypalenia zawodowego w zespołach windykacyjnych. Przykład KRUK S.A., który we współpracy z Alphamoon zautomatyzował miesięczne przetwarzanie do ponad 400 000 dokumentów, pokazuje, że wdrożenie elementów sztucznej inteligencji może zwiększyć szybkość ekstrakcji danych nawet o 70%. Dzięki funkcjom takim jak OCR, klasyfikacja dokumentów oraz NLP możliwe stało się usprawnienie procesu windykacji wierzytelności.

Kolejnym przykładem rozwiązania, po które chętnie sięga krajowy sektor finansowy, jest ROC3 (*Robotization of Company Customer Communication*), czyli zaawansowane rozwiązanie klasy *enterprise* zaprojektowane z myślą o transformacji cyfrowej skomplikowanych procesów zarządzania m.in. wierzytelnościami. Bazując na możliwościach generatywnej sztucznej inteligencji (modelu GPT-4), ROC3 zwiększa bezpieczeństwo korporacyjne (dzięki infrastrukturze Azure OpenAI) oraz elastyczność mikrousług, które można łatwo zintegrować z dowolnymi systemami informatycznymi w spółce windykacyjnej, a tym samym umożliwia m.in. automatyzację przetwarzania dokumentów czy wydobywanie brakujących danych. Dodatkowo ROC3 zwiększa możliwość wdrożenia rozwiązania w modelu *no-code*, pozwalającym tworzyć aplikacje lub procesy bez konieczności programowania.

ROC3 doskonale odpowiada na główne wyzwanie firm windykacyjnych, jakim jest gotowość na zmieniające się regulacje (Kondracki 2023). Przykładowe wdrożenia pokazują, że zastosowanie ROC3 może dwukrotnie zwiększyć liczbę obsługiwanych spraw przy niezmiennym liczebnie zespole i przy skróceniu czasu obsługi i automatyzacji spraw rutynowych. Z informacji marketingowych producenta wynika, że udane wdrożenia miały miejsce w banku Santander oraz Credit Agricole (Deviniti 2024).

3.4. Prototyp systemu zarządzania pismami procesowymi w spółce windykacyjnej

Analiza potrzeb jednej z polskich spółek windykacyjnych w zakresie zarządzania pismami procesowymi pokazuje, że mimo stosowanych już rozwiązań do ekstrakcji podstawowych danych i półautomatycznego generowania pism konieczne są dalsze usprawnienia. Umożliwią one poprawę obecnych procesów oraz analizę treści pism procesowych. Ocena merytoryczna zawartości pism procesowych wykonywana była przez pracowników działu prawnego

i dotychczas nie poddawano jej próbom automatyzacji. O ile obsługa całości postępowania w EPU może być prowadzona bez nadmiernego angażowania radców prawnych, o tyle w przypadku pism przychodzących z sądu (takich jak nakazy, wezwania do uzupełnienia braków formalnych czy postanowienia o umorzeniu), a zwłaszcza w przypadku pism procesowych w ramach procedury SWO (Sąd Właściwości Ogólnej), konieczne będzie zaangażowanie prawnika, chociażby w celu analizy treści pism i przygotowania merytorycznej odpowiedzi. Przypadek taki będzie miał miejsce m.in. przy złożeniu sprzeciwu przez dłużnika lub jego pełnomocnika. Dodatkowe ograniczenia wynikające ze specyfiki firmy wymagają, aby przetwarzanie danych poza spółką zredukowane zostało do absolutnego minimum. Dokumenty wytworzone w procesie windykacji zawierają dane osobowe dłużników, szczegóły finansowe, często również informacje objęte tajemnicą bankową czy telekomunikacyjną (w przypadku obsługi podmiotów ze wskazanych sektorów). Tym samym korzystanie wprost z narzędzi AI (zwłaszcza chmurowych, zewnętrznych) wymaga gwarancji poufności danych. Istnieje ryzyko, że wprowadzenie informacji o sprawie do modeli typu ChatGPT może naruszać interes zarówno dłużnika, jak i spółki windykacyjnej, np. w sytuacji, gdy dane wysłane do modelu zostaną utrwalone na serwerach dostawcy lub wykorzystane do uczenia modelu (Rojek-Socha i Sewastianowicz 2023).

Pismo procesowe stanowi dokument sformalizowany, zawierający tekst o charakterze prawnym, pełen specyficznej terminologii oraz specyficznych struktur (np. oznaczenia stron, sygnatury akt, powołania na podstawę prawną), a także intencji prawnych względem np. dłużnika. Dotychczas stosowana nieautomatyczna analiza takich dokumentów jest czasochłonna i bywa błędna. W proponowanym rozwiązaniu zdecydowano się na wykorzystanie inspiracji systemami wieloagentowymi. System MAS (*Multi-Agent System*) stanowi zbiór współdziałających ze sobą autonomicznych agentów, z których każdy realizuje określony zestaw zadań. W analizie dokumentów prawnych każdy agent odpowiada za określony aspekt przetwarzania treści pisma procesowego. Architektura MAS pozwala na rozproszenie realizowanych działań, również geograficzne, umożliwiając wykonywanie części zadań w infrastrukturze informatycznej spółki, przy jednoczesnym wykorzystaniu zewnętrznych serwisów do obsługi pozostałych procesów. Celem budowy systemu inspirowanego systemami multiagentowymi jest zautomatyzowanie analizy pisma procesowego w wyniku podziału zadania na wąsko wyspecjalizowane obszary oraz wykorzystania nowoczesnych modeli AI/NLP dostosowanych do polskiego języka prawniczego. Na rynku dostępne są gotowe rozwiązania MAS, z których kluczowymi są JADE (*Java Agent DEvelopment Framework*) (JADEF 2023) oraz SPADE (*Smart Python Agent DEvelopment Environment*). Dostarczana przez nie infrastruktura zgodna jest ze standardami FIPA (*Foundation for Intelligent Physical Agents*). JADE zaimplementowany został w języku JAVA, od lat chętnie wykorzystywanym w badaniach nad MAS. Dla porównania SPADE zaimplementowany został w języku Python i podobnie jak JADE wspiera standard FIPA, co przekłada się na zachowanie interoperacyjności między agentami i systemami zgodnymi z FIPA. Zaletą SPADE jest dodatkowo wykorzystanie do komunikacji protokołu XMPP, mającego za zadanie gwarantowanie bezpiecznej komunikacji między agentami.

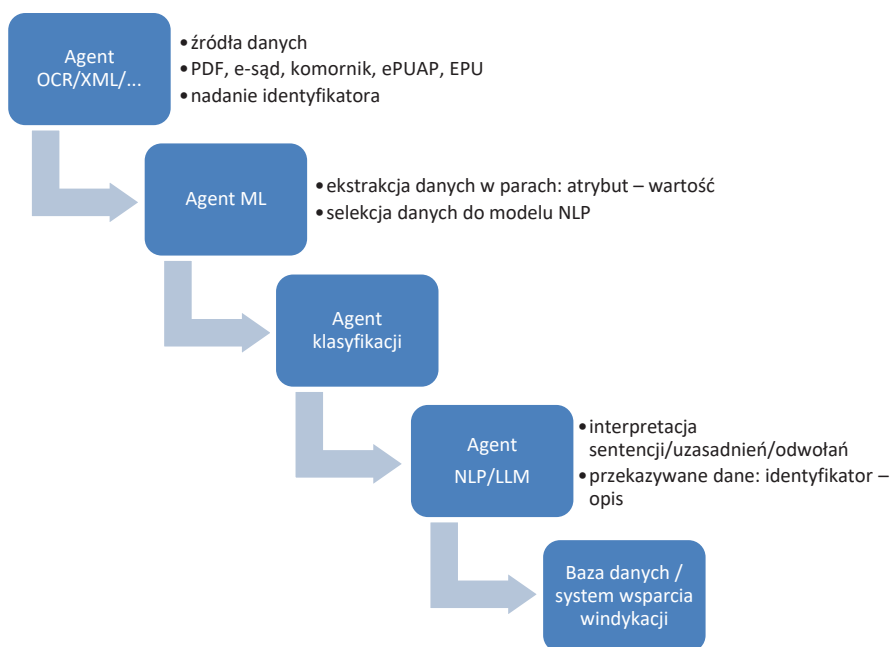
Architektura mikroserwisów, w której każdy agent funkcjonuje jako niezależny serwis komunikujący się z innymi, stanowi alternatywę dla platform MAS. Podejście oparte na zastosowaniu mikroserwisów nie narzuca formalnego języka komunikacji agentów jak chociażby FIPA-ACL, ale wykorzystuje sprawdzone, funkcjonujące technologie webowe oraz

wymiany komunikatów. Tym samym można osiągnąć zalety systemów wieloagentowych przy wykorzystaniu mniej skomplikowanych rozwiązań, jakim są mikroserwisy.

W inżynierii oprogramowania mikroserwis to architektoniczny wzorzec, który charakteryzuje się m.in. tym, że: stanowi samodzielną jednostkę aplikacyjną realizującą jedno konkretne zadanie (np. logowanie do systemu), może być niezależnie wdrażany i skalowany, a komunikację z innymi komponentami prowadzi głównie za pośrednictwem API. Architektura mikroserwisów tworzy aplikację, w skład której wchodzi dużo powiązanych, niezależnych usług (Matiolański 2023). Agent w AI to raczej koncepcja rozwiązania mogącego podejmować decyzje w sposób autonomiczny, rozwiązywać konkretne problemy lub podejmować reakcję na zdarzenia. Przykładem agenta AI może być narzędzie, które pobierając wiadomości e-mail, w sposób automatyczny planuje spotkania. Tego rodzaju usługi łączy się w taki sposób, aby mikroserwisy zawierały agenta AI, podobnie agent może korzystać z mikroserwisów (np. jako narzędzie). Żeby nie wprowadzać czytelnika w niuanse techniczne, związane z funkcjonowaniem poszczególnych modułów, w dalszej części rozdziału określenie agent będzie użyte w kontekście systemu realizującego wyznaczony cel, np. rozpoznanie tekstu, oraz utrwalającego efekt działania i zmianę stanu bazy danych.

Zakres oraz powiązania pomiędzy agentami w proponowanym prototypie przedstawiono na rysunku 3.2.

Podejście to wynika z wewnętrznych procedur bezpieczeństwa oraz oczekiwań kluczowych klientów z sektora bankowego. Zakres funkcjonalny oraz dobrane technologie zaprezentowano w tabeli 3.1.



Rys. 3.2. Koncepcja prototypu systemu obsługi pism procesowych

Tabela 3.1**Dobór rozwiązań technologicznych dla agentów systemu**

Agent	Zakres funkcjonalny	Wybrane technologie, rozwiązania
OCR/XLM/...	<ul style="list-style-type: none"> – pobieranie treści z ePUAP, e-sąd, ..., – rozpoznanie treści (w przypadku, kiedy wymagane), – integracja przez API z ePUAP, EPU, – nadanie identyfikatorów dokumentów 	<ul style="list-style-type: none"> – SFTP, – IMAP, – PyM – PDF (w wersji do pracy z plikami PDF lokalnie), – Tesseract Open Source OCR Engine
Agent ML	<ul style="list-style-type: none"> – wyszukiwanie wzorców w parach atrybut – wartość, – detekcja sygnatur, dat, stron postępowania, kwot, numerów PESEL / NIP, numerów umów, – odczyt metadanych 	<ul style="list-style-type: none"> – text-mining, – wyrażenia regularne, – LightGBM, – uczenie modeli na danych archiwalnych
Agent klasyfikacji	<ul style="list-style-type: none"> – klasyfikacja pism procesowych, – klasyfikacja treści 	<ul style="list-style-type: none"> – baza reguł, – wzory dokumentów, – scikit-learn, – orzeczenia.ms.gov.pl (API)
Agent NLP/LLM	<ul style="list-style-type: none"> – interpretacja treści opisowych, wymagających użycia NLP/LLM 	<ul style="list-style-type: none"> – spaCy, – Polish BERT, – przetwarzanie zewnętrzne (OpenAI API), dane przekazywane: identyfikator – zanonimizowana treść – prompt
Baza danych / system wsparcia windykacji	<ul style="list-style-type: none"> – przechowywanie pozyskanych danych, – przechowywanie faktów, – uzupełnianie danych, – aktualizacja stanu wiedzy 	<ul style="list-style-type: none"> – baza danych w podmiocie windykacyjnym, w analizowanym przypadku MS SQL Server

Prototyp systemu do analizy pism procesowych łączy specjalizację agentów. Dzięki modularnej architekturze każdy komponent (agent) może być rozwijany i skalowany niezależnie od innych komponentów systemu. Dodatkowo stwarza to możliwość przyszłego wykorzystania systemu w innych celach niż pierwotnie zakładane. Modułowość pozwala również na prace nad rozwojem każdego z agentów przez odrębny zespół IT oraz funkcjonowanie na różnych maszynach lub rozwiązaniach wirtualizujących. Dodatkowo w przyszłości wymiana modelu NLP lub LLM nie zakłóci pracy pozostałych agentów. Zaproponowane rozwiązanie daje również możliwość zrównoleglania działań w wyniku zwielokrotnienia instancji każdego z agentów, wraz ze wzrostem liczby obsługiwanych pakietów wierzytelności. Po wdrożeniu zaproponowanej koncepcji uzyskuje się zgodność z oczekiwaniami klienta, dzięki m.in. przekazywaniu do rozpoznania i interpretacji zewnętrznemu usługodawcy wyłącznie unikatowego identyfikatora pisma oraz treści pozbawionej danych umożliwiających identyfikację osób, relacji czy innych informacji, które ze względu na interes prawny dłużnika nie powinny być

przetwarzane poza siedzibą spółki windykacyjnej. Operacje zlecane na zewnątrz nie mogą w ten sposób być powiązane z dłużnikiem. Dodatkowo takie rozwiązanie przekłada się na redukcję kosztów korzystania z usług zewnętrznych, ponieważ do analizy przekazuje się objętościowo nie więcej niż 20–25% zawartości całego pisma. Zlecenie zadań na zewnątrz (np. z wykorzystaniem stale rozwijanych modeli LLM) zwiększa trafność interpretacji przekazywanych treści, przy jednoczesnym braku konieczności ponoszenia kosztów trenowania własnych modeli. Koszty ograniczają się jedynie do opłat za liczbę zużytych tokenów: wejściowych, wyjściowych oraz tzw. tokenów cache'owych. Zgodnie z literaturą przedmiotu podejście to wpisuje się w założenia architektury wieloagentowej i może okazać się bardziej efektywne niż tradycyjne rozwiązania monolityczne. Dzięki rozdzieleniu zadań na wyspecjalizowane komponenty osiąga się wyższą niezawodność budowanego rozwiązania w wyniku współdzielenia informacji pomiędzy agentami oraz krzyżowej weryfikacji wyników.

3.5. Analiza ekonomiczna wdrożenia prototypu systemu zarządzania pismami procesowymi

Wdrożenie proponowanego rozwiązania – prototypu systemu obsługi pism procesowych wspieranego przez AI – przy przyjętych założeniach technologicznych wymaga inwestycji w rozwój oprogramowania i infrastruktury. Potencjalne korzyści z uruchomienia oraz utrzymania systemu mogą jednak istotnie przewyższyć poniesione nakłady. Analizując kluczowe aspekty ekonomiczne, takie jak redukcja kosztów operacyjnych, zwrot z inwestycji (ROI) oraz porównanie szacunków efektywności z upublicznionymi wynikami wdrożeń AI w sektorze finansowym, można uzasadnić opłacalność takiego przedsięwzięcia. Z uwagi na konieczność ochrony interesów przykładowej spółki nie wszystkie dane zostaną opublikowane. W takim przypadku podane zostaną dane z upublicznionych wdrożeń sztucznej inteligencji pochodzących z sektora usług finansowych. Dane te zostały skonfrontowane z rzeczywistymi danymi i w przypadku istotnych rozbieżności zostało to wyraźnie zaznaczone. W zakresie oszczędności czasu pracy działu prawnego zakłada się, że automatyzacja czynności prawnych umożliwia redukcję czasu obsługi pisma procesowego (z procedurze SWO) z wielu godzin do 3–5 minut. Przy aktualnym wolumenie obsługiwanych spraw, w omawianym przypadku daje ok. 780 oszczędzonych godzin pracy działu prawnego miesięcznie, co przekłada się na możliwość redukcji zatrudnienia w dziale o 4–5 osób. Przykładowe dane w innych wdrożeniach wskazują na zwiększenie wydajności zespołów windykacyjnych 2–4-krotnie. W zakresie redukcji kosztów operacyjnych zakłada się, że wdrożenie nie tylko przełoży się na ograniczenie potrzeby zatrudniania dodatkowego personelu przy rosnącym wolumenie spraw kierowanych na drogę sądową, lecz także będzie skutkowało redukcją opłat karnych za nieterminowe wykonanie zleceń w ramach świadczenia usług windykacyjnych w modelu serwisowym. Szacunki na danych rzeczywistych potwierdzają doniesienia z raportów prasowych, że koszty operacyjne ulegają redukcji o 30–50%. W kontekście zwrotu z inwestycji (ROI) początkowe nakłady związane z rozbudową posiadanej infrastruktury IT – obejmujące zakup serwerów, rozwój oprogramowania, integrację z serwisami zewnętrznymi oraz koszty wdrożenia – według danych prasowych zwracają się średnio w ciągu roku od zakończenia projektu (Erp-view 2025).

W analizowanym przypadku okres ten jest znacznie krótszy z uwagi na posiadane przez spółkę zasoby IT. Istotne również jest to, że po stronie kosztowej pozostają koszty utrzymania (konserwacji) rozwiązania oraz skalowalność proponowanego rozwiązania. Koszty utrzymania rozwiązania wynikają m.in. z kosztów dostępu do mocy obliczeniowej (opłata za wykorzystane tokeny), aktualizacji systemu obsługi pism procesowych do regulacji prawnych oraz administracji systemu. Koszty te, ze względu na wykorzystanie modeli LLM jedynie do niewielkiej części analizowanych pism (ponad 70% analiz odbywa się lokalnie), są niższe w porównaniu z rozwiązaniami, w których całe pisma przetwarzane są z wykorzystaniem usług zewnętrznych. Nie bez znaczenia pozostają również korzyści trudne do jednoznacznej wyceny, związane z niematerialnymi aspektami wdrożenia. Należą do nich m.in. zwiększenie satysfakcji pracowników dzięki eliminacji monotonnych zadań, zapewnienie zgodności z regulacjami (np. w zakresie dotrzymywania terminów) oraz ułatwienie procesów raportowania.

Transformacja podejścia do zarządzania pismami procesowymi w spółkach windykacyjnych, od modelu tradycyjnego, nastawionego na manualne działania pracowników biurowych, po zaawansowane systemy wspomagane sztuczną inteligencją, przebiegała stopniowo. Historycznie rzecz ujmując, dokumentacja była tworzona manualnie, co generowało znaczne koszty, ryzyko błędów oraz ograniczało skalowalność lub przynajmniej wiązało się z proporcjonalnym wzrostem zatrudnienia w dziale prawnym. Wdrożenie narzędzi OCR, klasyfikacji pism, ekstrakcję danych z wykorzystaniem text-miningu, wyrażeń regularnych, a następnie NLP umożliwiło stopniową automatyzację. Proponowanym rozwiązaniem obsługi pism procesowych jest budowa systemu inspirowanego architekturą systemów wieloagentowych, w którym każdy agent odpowiada za ściśle określone zadania, takie jak: OCR, klasyfikacja, ekstrakcja danych czy analiza intencji. Przyjęty model architektury pozwala na elastyczne skalowanie, bezpieczne przetwarzanie danych i wykorzystanie zarówno lokalnych zasobów, jak i zewnętrznych usług AI, przy minimalnym ryzyku naruszenia poufności danych.

4. Uczenie maszynowe na zbiorach niezbalansowanych w problemach zarządzania

4.1. Metodyka przetwarzania niezbalansowanych danych

W praktyce gospodarczej często mamy do czynienia z sytuacjami, w których kluczowe zjawisko pojawia się względnie rzadko, a właśnie to zjawisko ma główne znaczenie dla przedsiębiorstwa. Przykładowo, klienci kupujący produkty w sklepie internetowym stanowią niewielki odsetek odwiedzających witrynę internetową. Kredytobiorcy niespłacający kredytu są niezbyt liczną grupą klientów banku. Przypadki nadużyć finansowych pojawiają się rzadko w systemie finansowym. Przykładów można podać znacznie więcej, ale głównym problemem w analizie tego typu zjawisk jest niewielki udział przypadków docelowych w posiadanych zbiorach danych historycznych. Prowadzi to do znacznych problemów z identyfikacją danego zjawiska oraz wysokich kosztów błędnych decyzji (Paliński 2013a, 2013b).

Z danymi niezbalansowanymi mamy do czynienia wtedy, gdy liczba obserwacji z poszczególnych klas w zbiorze danych znacznie się różni. Zwykle głównym celem jest poprawne rozpoznawanie przypadków z klasy mniejszościowej, np. niewypłacalność kredytobiorcy, upadłość, oszustwa ubezpieczeniowe, podatkowe itp. Klasyfikacja i uczenie maszynowe na zbiorze niezbalansowanym stanowi duże wyzwanie, gdyż algorytmy uczenia maszynowego, optymalizując funkcję celu, dążą do poprawy trafności klasyfikacji, bez względu na klasę przynależności poszczególnych przypadków. W związku z tym klasa mniejszościowa traci na znaczeniu. Podstawowym problemem związanym z eksploracją danych niezbalansowanych jest jednak to, że błędna klasyfikacja rzadkich zdarzeń z klasy mniejszościowej może skutkować wysokimi kosztami.

Główne trudności w trakcie uczenia algorytmów na zbiorach niezbalansowanych wynikają z tego, że:

- standardowe metody uwzględniają zrównoważone dane,
- strategie klasyfikacji sprzyjają klasom większościowym,
- pojawiają się trudności w odróżnieniu błędnych danych (szumu) od przypadków z klasy mniejszościowej.

Poniżej wymieniono grupy metod rozwiązujących problem niezbalansowanych danych spotykane w literaturze (Galar i in. 2012; He i Garcia 2009; Maalouf i Trafalis 2011; Mahani i Ali 2019).

- Metody modyfikacji danych – tzw. podejście zewnętrzne, w którym dane przetwarzają się przed zastosowaniem klasyfikatorów. Dane są niezależne od wybranego algorytmu uczenia klasyfikatora.

- Metody modyfikacji algorytmów – tzw. podejście wewnętrzne, w którym klasyczne algorytmy wzbogaca się o mechanizmy uwzględniające dysproporcję klas. W ramach tego podejścia stosuje się indukcyjne ukierunkowanie (*inductive bias*) oraz uczenie, w którym brane są pod uwagę tylko przykłady z klasy mniejszościowej, bez przykładów z pozostałych klas. Druga metoda w tym podejściu to transformacje do zadania wrażliwego na koszt (*cost-sensitive learning*). Dane wejściowe są modyfikowane przez nadanie im różnych wag (kosztów) lub algorytmy uczenia wzbogacane są o mechanizmy uwzględniające różne wagi nadane obserwacjom.
- Metody hybrydowe – stanowiące kombinację poprzednich metod.

Podejście zewnętrzne opierające się na modyfikacji zbiorów danych jest najczęściej stosowaną metodą w uczeniu na zbiorach niezbalansowanych. Najogólniej istnieją dwa rodzaje modyfikacji pierwotnego zbioru danych (Mahani i Ali 2019): undersampling – polegający na usuwaniu obserwacji z klasy dominującej oraz oversampling – polegający na sztucznym generowaniu obserwacji z klasy mniejszościowej. Spośród metod undersamplingu najczęściej wykorzystywane są: Random Undersampling, Cluster Centroid Undersampling, Tomek Links Undersampling, NearMiss-1, NearMiss-2, Edited Nearest Neighbours, Neighbourhood Cleaning Rule i Condensed Nearest Neighbours. Najbardziej popularne metody oversamplingu to: Random Oversampling, SMOTE, Borderline-SMOTE, SVM-SMOTE, ROSE i ADASYN.

Random Undersampling (RUS) – to metoda polegająca na losowym usuwaniu obserwacji z klasy większościowej aż do momentu uzyskania pożądanej proporcji względem klasy mniejszościowej. Jest to jedno z najprostszych podejść do radzenia sobie z niezbalansowanymi danymi, jednak jego zastosowanie wiąże się z ryzykiem utraty istotnych informacji (Krawczyk 2016).

Cluster Centroid Undersampling – technika ta zmniejsza liczebność klasy większościowej, zastępując pewne grupy danych (klastry) ich centroidami. Na początku algorytm ustala proporcję między klasą większością a mniejszością, po czym wykorzystuje metodę k -średnich do utworzenia klastrów w obrębie klasy większościowej. Następnie losowo wybiera przypadki, na podstawie których wyliczane są centroidy, a te – połączone z danymi z pozostałych klas – tworzą nowy zbiór danych (Show-Jane i Yue-Shi 2009).

Tomek Links – metoda rozszerzająca koncepcję k -najbliższych sąsiadów. Polega na identyfikacji par przypadków z różnych klas, które są dla siebie najbliższymi sąsiadami. Takie pary nazywane są „Tomek links” – zwykle jeden lub oba przypadki z takiej pary leżą na granicy klas lub stanowią szum. W zależności od przyjętej strategii usuwane są albo tylko przypadki z klasy większościowej, albo oba elementy pary. Pozwala to na zmniejszenie liczby przypadków z klasy dominującej oraz lepsze określenie granic między klasami (Mahani i Ali 2019).

Algorytm NearMiss – występuje w trzech wariantach: NearMiss-1, NearMiss-2 i NearMiss-3. Wszystkie mają na celu redukcję liczby przykładów z klasy większościowej, które znajdują się blisko obserwacji z klasy mniejszościowej. W NearMiss-1 usuwane są te przypadki z klasy większościowej, które są najbliższe trzem sąsiednim przypadkom z klasy mniejszościowej. NearMiss-2 koncentruje się na przypadkach leżących najbliżej najbardziej

odległych obserwacji klasy mniejszościowej. NearMiss-3 zapewnia, że każdy przypadek z klasy mniejszościowej jest otoczony przez określoną liczbę przypadków z klasy większościowej (Zhang i Mani 2003).

Edited Nearest Neighbours (ENN) – technika polegająca na analizie sąsiedztwa każdej obserwacji z klasy większościowej. Dla każdej z nich sprawdza się, do jakich klas należą jej k -najbliżsi sąsiedzi (zwykle $k = 3$). Jeżeli większość sąsiadów pochodzi z innej klasy niż analizowany przypadek, zostaje on usunięty jako potencjalnie błędnie sklasyfikowany. Metoda ta pomaga zredukować szum oraz przypadki trudne do klasyfikacji, co skutkuje wyraźniejszymi granicami decyzyjnymi (Alejo i in. 2010).

Neighbourhood Cleaning Rule (NCL) – opiera się na zasadach algorytmu ENN, lecz rozszerza je o klasę mniejszościową. Algorytm NCL identyfikuje przypadki z klasy mniejszościowej, które zostały źle sklasyfikowane, a następnie usuwa trzech (lub więcej) najbliższych sąsiadów z klasy większościowej. Pozwala to na czyszczenie danych i eliminację przykładów, które mogą wprowadzać trudności podczas trenowania modelu (Agustianto i Destarianto 2019).

Condensed Nearest Neighbours (CNN) – algorytm ten służy do zmniejszania rozmiaru zbioru treningowego, polegającego na wyborze tylko najbardziej reprezentatywnych przypadków dla klasyfikacji. Działa na zasadzie iteracyjnego sprawdzania, które obserwacje mogą być poprawnie sklasyfikowane przez obecny zbiór uczący. Obserwacje uznane za łatwe do sklasyfikowania (czyli takie, które mają sąsiadów z tej samej klasy) są usuwane, a do nowego zbioru dodawane są tylko te, które są niezbędne do prawidłowej klasyfikacji. Proces powtarzany jest do momentu, w którym nie będzie więcej przypadków do dodania (Mahani i Ali 2019).

Random Oversampling – metoda polegająca na losowym powielaniu obserwacji z klasy mniejszościowej aż do osiągnięcia wymaganej proporcji względem klasy większościowej. Chociaż jest to prosta i często stosowana technika, może prowadzić do przeuczenia modelu ze względu na powielanie tych samych danych (Krawczyk 2016).

SMOTE (Synthetic Minority Oversampling Technique) – algorytm generujący syntetyczne przykłady z klasy mniejszościowej. Dla każdego przypadku w tej klasie identyfikowani są k -najbliżsi sąsiedzi (należący również do tej klasy), a następnie losowo wybierany sąsiad służy do wygenerowania nowego punktu znajdującego się w losowym miejscu na odcinku łączącym oba przypadki. Proces ten jest powtarzany aż do osiągnięcia pożądaných proporcji (Mahani i Ali 2019).

Borderline-SMOTE – wariant SMOTE, który skupia się na przykładach z klasy mniejszościowej znajdujących się w pobliżu granicy decyzyjnej. Przypadki są klasyfikowane jako bezpieczne, graniczne lub będące szumem. Nowe dane generowane są tylko dla przypadków granicznych, które najczęściej sąsiadują z obserwacjami z klasy większościowej, co pozwala lepiej zbalansować trudne obszary przestrzeni cech (Mahani i Ali 2019).

SVM-SMOTE – algorytm zbliżony do Borderline-SMOTE, który do określania granicy między klasami wykorzystuje metodę SVM, a nie k -najbliższych sąsiadów. Sztuczne przypadki są tworzone wokół granicy wyznaczonej przez SVM, przez interpolację lub ekstrapolację względem sąsiadujących punktów (Zheng 2020).

ROSE (Random Over Sampling Examples) – metoda oparta na przybliżeniu rozkładu prawdopodobieństwa klasy mniejszościowej i symulowaniu z niego nowych obserwacji. ROSE estymuje rozkład $P(x|y = k)$ dla każdej klasy, a następnie generuje próbki zgodnie z tym rozkładem. Proces ten może być modyfikowany za pomocą funkcji jądrowych, które stanowią hiperparametr modelu (Menardi i Torelli 2014).

ADASYN (Adaptive Synthetic Sampling) – adaptacyjna metoda generowania syntetycznych danych podobna do SMOTE, ale bardziej skoncentrowana na obszarach trudnych do klasyfikacji. Obserwacje z klasy mniejszościowej, które znajdują się w otoczeniu zdominowanym przez klasę większościową, otrzymują większy priorytet przy generowaniu nowych danych. Tworzenie obserwacji przebiega analogicznie jak w SMOTE, ale z uwzględnieniem wag określających poziom trudności klasyfikacji (He i in. 2008).

W dalszej części rozdziału zastosowane zostanie podejście zewnętrzne polegające na preprocessingu (modyfikacji) niezbalansowanych danych oraz podejście wewnętrzne wykorzystujące modyfikację wag klas na poziomie algorytmu wraz z ewentualną modyfikacją zbioru danych uczących.

W przypadku zbiorów niezbalansowanych konieczne jest także przyjęcie bardziej szczegółowych miar trafności klasyfikacji niż tylko trafność całkowita. Ocena trafności klasyfikacji opiera się na macierzy pomyłek (tab. 4.1). Układ tabeli 4.1, w której w wierszach są wartości rzeczywiste, a w kolumnach wartości przewidywane, odpowiada standardowemu układowi biblioteki Scikit-learn (2025) wykorzystywanej w dalszej części rozdziału w badaniach empirycznych.

Tabela 4.1
Macierz pomyłek

		Przewidywane		suma
		klasa negatywna	klasa pozytywna	
Rzeczywiste	klasa negatywna	prawdziwie negatywne (TN)	fałszywie pozytywne (FP)	TN + FP
	klasa pozytywna	fałszywie negatywne (FN)	prawdziwie pozytywne (TP)	FN + TP
suma		TN + FN	FP + TP	

Źródło: opracowanie własne na podstawie (Scikit-learn 2025; Vujović 2021)

Na podstawie macierzy pomyłek można wprowadzić poniższe wskaźniki trafności klasyfikacji przydatne w ocenie jakości klasyfikacji zbiorów niezbalansowanych (Vujović 2021).

Dokładność (*accuracy*) – stosunek poprawnie zakwalifikowanych obserwacji do całości próby. Określa ją wzór:

$$accuracy(ACC) = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

Precyzja (*precision*) – proporcja obserwacji pozytywnych, które zostały zakwalifikowane prawidłowo. Określa ją wzór:

$$precision(PP) = \frac{TP}{TP + FP} \quad (4.2)$$

Czułość (*sensitivity, recall, true positive rate*) – relacja poprawnie sklasyfikowanych klasyfikacji pozytywnych do ogólnej liczby obserwacji pozytywnych wprowadzonych do modelu. Wysoka wartość tej miary wskazuje na skuteczne wykrywanie przypadków klasy pozytywnej. Czułość określona jest wzorem:

$$sensitivity(SN) = \frac{TP}{TP + FN} \quad (4.3)$$

Swoistość (*specificity, true negative rate*) – stosunek prawidłowo sklasyfikowanych obserwacji klasy negatywnej do wszystkich negatywnych predykcji. Określa ją wzór:

$$specificity(SP) = \frac{TN}{TN + FP} \quad (4.4)$$

F1-Score – średnia harmoniczna precyzji i czułości. Określa ją wzór:

$$F1 = \frac{2 \cdot PP \cdot SN}{PP + SN} = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \quad (4.5)$$

Współczynnik korelacji Matthews (*Matthews Correlation Coefficient*) – korelacja między przewidywanymi klasami, miara zalecana dla zbiorów niezbalansowanych. Określa ją wzór:

$$MCC = \frac{TN \cdot TP - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (4.6)$$

W dalszej części wykorzystane zostaną przede wszystkim wskaźniki: accuracy ACC mierzący ogólną trafność klasyfikacji oraz sensitivity SN mierzący poprawność klasyfikacji klasy pozytywnej. Ponadto obliczone zostaną wskaźniki F1 oraz korelacji Matthews.

4.2. Zbiór danych i metodyka badań

W badaniu wykorzystano zbiór danych Loan Raw Data pochodzący z dużego zestawu danych LendingClub, zawierającego informacje na temat udzielonych kredytów – łącznie blisko 900 tys. rekordów (Kaggle 2025).

Zbiór Loan Raw Data obejmuje 52 zmienne: loan_amount, funded_amount, investor_funds, term, interest_rate, installment, grade, sub_grade, emp_length, home_ownership, annual_income, verification_status, issue_d, loan_status, pymnt_plan, purpose, addr_state, dti, delinq_2yrs, earliest_cr_line, inq_last_6mths, open_acc, pub_rec, revol_bal, revol_util,

total_acc, initial_list_status, out_prncp, out_prncp_inv, total_pymnt, total_pymnt_inv, total_rec_prncp, total_rec_int, total_rec_late_fee, recoveries, collection_recovery_fee, last_pymnt_d, final_d, last_pymnt_amnt, last_credit_pull_d, collections_12_mths_ex_med, policy_code, application_type, acc_now_delinq, year, loan_condition, region, complete_date, emp_length_int, income_category, loan_condition_int, interest_payments.

Loan Raw Data zawiera zmienne określające m.in.:

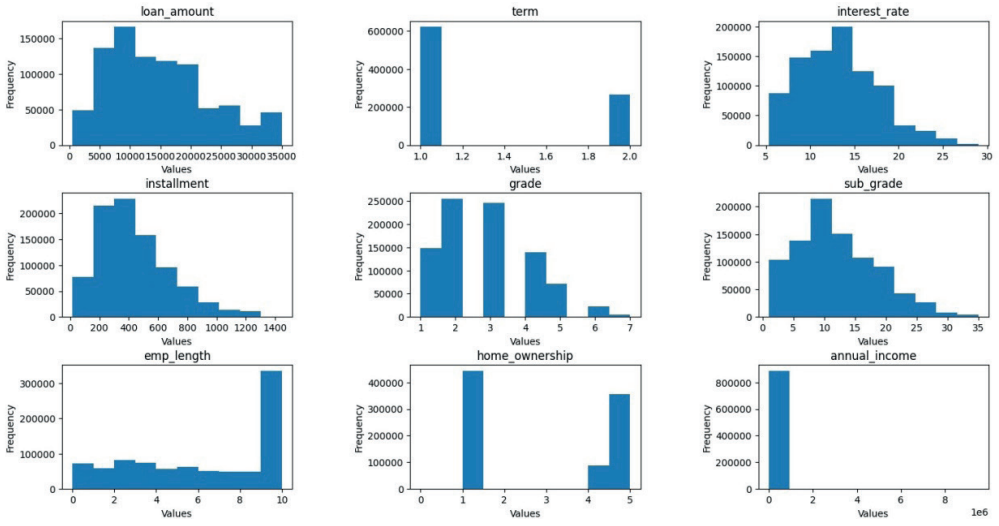
- loan_status (zmienna objaśniana): obecny status kredytu, przyjmuje wartości: “Current” (obecna), “Fully Paid” (pożyczka w pełni spłacona), “Charged Off” (pożyczka umorzona), “Late (31–120 days)” (opóźnienie w płatności 31–120 dni), “Issued” (pożyczka udzielona), “Late (16–30 days)” (opóźnienie w płatności 16–30 dni), “Does not meet the credit policy. Status: Fully Paid” (nie spełnia warunków kredytu – w pełni spłacona), “Default” (pożyczka niespłacona), “Does not meet the credit policy. Status: Charged Off” (nie spełnia warunków kredytu – umorzona);
- zmienne dotyczące kwot kredytu;
- zmienne charakteryzujące kredytobiorcę;
- zmienne charakteryzujące rodzaj i warunki kredytu;
- zmienne opisujące proces spłaty kredytu w czasie.

Zmienną loan_status (zmienna objaśniana) przekształcono na zmienną binarną, dokonując podziału obecnego statusu kredytu na dwie klasy w wyniku przypisania zmiennej następujących wartości:

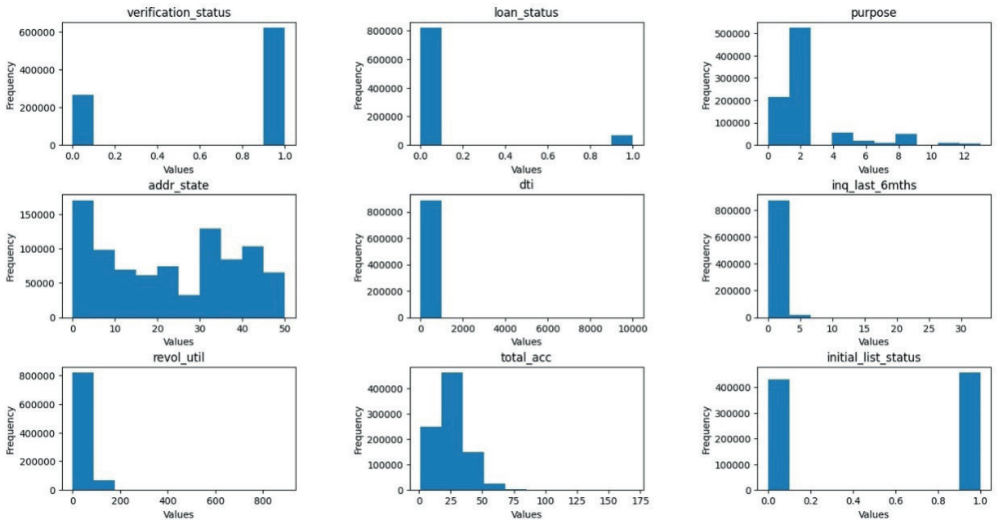
- 1 – dla wartości: “Charged Off”, “Default”, “Does not meet the credit policy. Status: Charged Off”, “In Grace Period”, “Late (16–30 days)”, “Late (31–120 days)” – wartości oznaczające, że kredytobiorca nie wywiązał się z warunków umowy;
- 0 – dla wartości: “Current”, “Fully Paid”, “Does not meet the credit policy. Status: Fully Paid”, “Issued” – wartości oznaczające, że kredytobiorca wywiązał się z warunków umowy lub jest w jej trakcie i nie popełnił żadnych błędów.

Ze zbioru usunięto trzy zmienne, dla których występowała bardzo duża liczba braków danych. Zbiór Loan Raw Data jest zbiorem niezbalansowanym. Zmienna loan_status przyjmuje wartość 1 w około 7,6% przypadków oraz wartość 0 w około 92,4% przypadków.

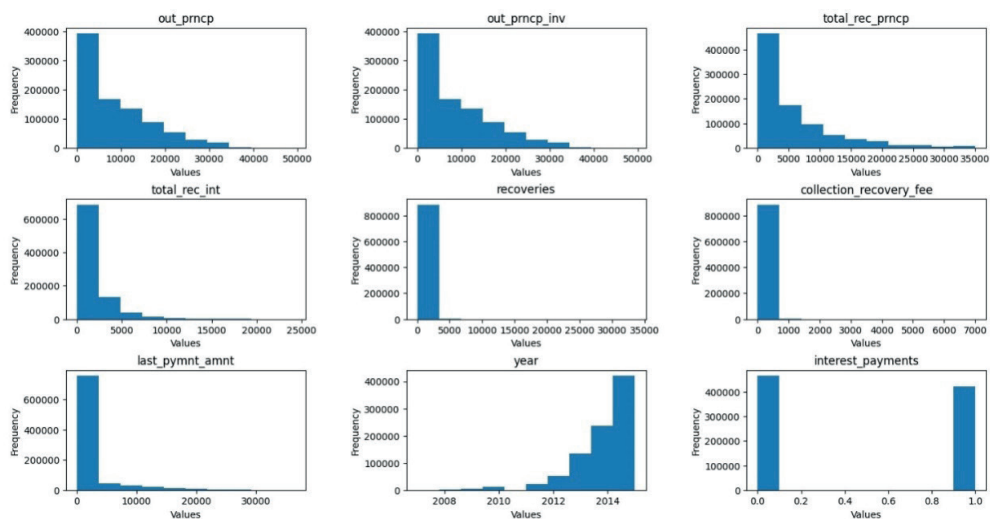
W trakcie procesu przygotowania danych ze zbioru Loan Raw Data usunięto trzynaście zmiennych liczbowych, które nie wykazywały zależności ze zmienną objaśnianą loan_status. Usunięto także sześć zmiennych typu data, ze względu na brak bezpośredniego związku daty zdarzenia z wynikiem spłaty kredytu. Dwie zmienne zostały usunięte ze zbioru ze względu na bardzo małe zróżnicowanie wartości. Osiem zmiennych kategorycznych, które można było umieścić na skali porządkowej, zamieniono na zmienne liczbowe. Pozostałe cztery zmienne kategoryczne zakodowano w postaci liczbowej, ze względu na dużą liczbę wartości występujących dla tych zmiennych. Po powtórnej analizie danych usunięto dodatkowo trzy zmienne. Braki danych występujące dla pięciu zmiennych uzupełniono za pomocą interpolacji liniowej. Ostatecznie w zbiorze danych pozostało dwadzieścia sześć liczbowych zmiennych objaśniających i jedna zmienna objaśniana. Zbiór zawierał finalnie 887 379 obserwacji. Histogramy zmiennych zostały przedstawione na rysunkach 4.1–4.3.



Rys. 4.1. Histogramy zmiennych, cz. 1



Rys. 4.2. Histogramy zmiennych, cz. 2



Rys. 4.3. Histogramy zmiennych, cz. 3

4.3. Wyniki badań

Na pierwszym etapie badań dla analizowanego zbioru danych zbudowano modele z wykorzystaniem klasycznych metod uczenia maszynowego:

- KNN (metoda k -najbliższych sąsiadów),
- regresja logistyczna,
- drzewa klasyfikacyjne,
- bagging (klasyfikator bazowy – drzewa klasyfikacyjne),
- boosting (klasyfikator bazowy – drzewa klasyfikacyjne).

Początkowo dla mniejszego podzbioru danych Loan Raw Data sprawdzono metody bagging i boosting z użyciem dwóch klasyfikatorów bazowych: drzew klasyfikacyjnych oraz klasyfikatora SVM. Zdecydowano jednak o zastosowaniu w dalszym badaniu modeli tworzonych z wykorzystaniem drzew decyzyjnych z uwagi na znacznie gorszą wartość metryk uzyskanych dla klasyfikatora bazowego SVM. Ponadto ze względu na duży rozmiar zbioru danych Loan Raw Data metoda SVM z powodu bardzo długiego czasu obliczeń nie miałyby praktycznego zastosowania. Początkowo na mniejszym podzbiórze danych dla metod, takich jak: KNN, regresja logistyczna, bagging i boosting zbudowano modele dla różnych wartości hiperparametrów, tak aby wybrać jak najlepsze wartości. Po dokonaniu wyboru hiperparametrów dalsze badanie przeprowadzono dla tych samych wartości parametrów dla całego zbioru danych. Obliczenia wykonywane były na komputerze z dwoma procesorami Intel Xeon Silver 4210, 128 GB RAM z systemem operacyjnym Windows Server 2019 Datacenter. W tabeli 4.2 przedstawiono wyniki zastosowania dla pierwotnego niezbalansowanego zbioru danych.

Tabela 4.2

Metryki klasyfikacji dla pierwotnego zbioru danych z użyciem niezmodyfikowanych metod uczenia maszynowego

Metoda	ACC	SN	F1	MCC
KNN	0,96	0,44	0,60	0,63
Regresja logistyczna	0,95	0,34	0,51	0,57
Drzewa klasyfikacyjne	0,95	0,73	0,71	0,69
Bagging (drzewo klasyfikacyjne)	0,98	0,70	0,82	0,82
Boosting (drzewo klasyfikacyjne)	0,95	0,73	0,71	0,69

Najgorsze wyniki uzyskano dla regresji logistycznej, a najlepsze dla metody bagging użytej w połączeniu z drzewami klasyfikacyjnymi. W każdym przypadku wartość wskaźnika accuracy ACC była bardzo wysoka, jednak wartości pozostałych metryk wskazują, że modele niezbyt dobrze radzą sobie z klasyfikacją przypadków z klasy mniejszościowej. Relatywnie dobrze poradziły sobie modele oparte na drzewie decyzyjnym, zapewniając wskaźnik czułości (SN) na poziomie 0,70–0,73.

Na tym etapie badania można zauważyć, że dla analizowanych zbiorów danych niektóre metody, takie jak drzewa klasyfikacyjne oraz bagging i boosting w połączeniu z drzewami klasyfikacyjnymi lepiej radzą sobie z klasyfikacją przypadków z klasy mniejszościowej niż regresja logistyczna i metoda k -najbliższych sąsiadów (KNN).

Na kolejnym etapie badań zastosowano metodę losowego usunięcia obserwacji z klasy większościowej – undersamplingu. Ze względu na długi czas obliczeń i wysokie wymagania sprzętowe zrezygnowano z bardziej wyrafinowanych metod undersamplingu, takich jak: Cluster Centroid Undersampling, Tomek Links Undersampling, Neighbourhood Cleaning Rule i inne. Zastosowano jedynie podstawową metodę Random Undersampling. Wyniki otrzymanych modeli zawarto w tabeli 4.3. Bardziej zaawansowane metody losowej eliminacji przypadków z klasy większościowej zostały użyte w dalszej części badań w trakcie uczenia sztucznej sieci neuronowej.

Tabela 4.3

Metryki klasyfikacji dla zbioru danych zbalansowanego za pomocą techniki Random Undersampling z użyciem niezmodyfikowanych metod uczenia maszynowego

Metoda	ACC	SN	F1	MCC
KNN	0,71	0,86	0,31	0,31
Regresja logistyczna	0,72	0,83	0,31	0,31
Drzewa klasyfikacyjne	0,08	0,99	0,14	0,00
Bagging (drzewo klasyfikacyjne)	0,08	0,99	0,14	0,00
Boosting (drzewo klasyfikacyjne)	0,08	0,99	0,14	0,00

Metoda losowego usunięcia części obserwacji z klasy większościowej przyniosła znaczącą poprawę wskaźnika czułości SN, przy drastycznym pogorszeniu wskaźnika ogólnej jakości klasyfikacji accuracy ACC, szczególnie w odniesieniu do metod wykorzystujących drzewa decyzyjne. Metoda ta okazała się umiarkowanie skuteczna w przypadku algorytmów KNN i regresji logistycznej.

Na następnym etapie wykonano badanie z zastosowaniem losowego nadpróbkowania – Random Oversampling. Podobnie jak w poprzednim przypadku, z uwagi na duży koszt obliczeniowy zrezygnowano z bardziej zaawansowanych metod oversamplingu, takich jak: SMOTE, Borderline-SMOTE, SVM-SMOTE, ROSE i ADASYN. Zaawansowane metody oversamplingu zostały wykorzystane na dalszym etapie badań w procesie uczenia sztucznej sieci neuronowej. Miary oceny trafności klasyfikacji utworzonych modeli zawarte są w tabeli 4.4.

Tabela 4.4

Metryki klasyfikacji dla zbioru danych zbalansowanego za pomocą techniki random oversampling z użyciem niezmodyfikowanych metod uczenia maszynowego

Metoda	ACC	SN	F1	MCC
KNN	0,85	0,99	0,50	0,53
Regresja logistyczna	0,75	0,87	0,34	0,35
Drzewa klasyfikacyjne	0,08	0,99	0,14	0,00
Bagging (drzewo klasyfikacyjne)	0,08	0,99	0,14	0,00
Boosting (drzewo klasyfikacyjne)	0,08	0,99	0,14	0,00

Metoda losowego nadpróbkowania części obserwacji z klasy mniejszościowej przyniosła wyraźną poprawę wskaźnika czułości SN, przy drastycznym pogorszeniu wskaźnika ogólnej jakości klasyfikacji accuracy ACC w przypadku metod wykorzystujących drzewa decyzyjne. Metoda ta okazała się skuteczna w przypadku algorytmów KNN, gdzie przyniosła bardzo dobre wyniki, oraz regresji logistycznej. Problematyczny jednak okazał się czas obliczeń wielokrotnie przekraczający czas obliczeń pozostałych algorytmów, w szczególności w przypadku metody k -najbliższych sąsiadów. Większość metod wymagała czasu poniżej połowy godziny, podczas gdy metoda KNN w przypadku dużego zbioru danych powiększonego w wyniku oversamplingu potrzebowała blisko czterech godzin obliczeń.

Kolejnym sposobem niwelowania problemów wynikających z przetwarzania niezbalansowanych danych są metody, które opierają się na modyfikacjach wprowadzanych na poziomie algorytmu. Do takich metod można zaliczyć m.in. modyfikację wag klas oraz modyfikację funkcji kosztów. W tej części badania skupiono się na modyfikacji wag klas, która w sposób niejawni wpływa również na modyfikację funkcji kosztu. Wagi klas zostały automatycznie obliczone dla każdego z pięciu zbiorów danych na podstawie liczności występowania każdej klasy w zbiorze. Zostało to wykonane tak, aby zrównoważyć wpływ każdej klasy na wynik uczenia klasyfikatora. Z tego powodu klasa rzadziej występująca otrzymała wyższą wagę, a klasa występująca częściej otrzymała niższą wagę. Wagi klas w algorytmach bagging i boosting zostały zmodyfikowane w odniesieniu do klasyfikatorów bazowych – drzew decyzyjnych.

Modyfikacji wag klas nie zastosowano w metodzie KNN ze względu na jej konstrukcję i brak możliwości implementacji takiego rozwiązania. Metryki trafności klasyfikacji utworzonych modeli przedstawione są w tabeli 4.5.

Tabela 4.5

Metryki klasyfikacji dla pierwotnego zbioru danych z użyciem metod uczenia maszynowego zmodyfikowanych na podstawie wag klas

Metoda	ACC	SN	F1	MCC
Regresja logistyczna	0,94	0,74	0,63	0,61
Drzewa klasyfikacyjne	0,96	0,72	0,72	0,69
Bagging (drzewo klasyfikacyjne)	0,98	0,69	0,82	0,82
Boosting (drzewo klasyfikacyjne)	0,96	0,72	0,72	0,69

W kolejnym kroku przeprowadzono badanie z wykorzystaniem sztucznej sieci neuronowej. Była to główna część badań uwzględniająca współczesne trendy uczenia maszynowego skupiające się na zastosowaniu sieci neuronowych w dowolnych obszarach życia gospodarczego i społecznego. Wzięta została pod uwagę sieć typu wielowarstwowy perceptron MLP. Jest to klasyczny już rodzaj sieci, który umożliwia rozwiązywanie złożonych zadań klasyfikacji przy umiarkowanych wymaganiach obliczeniowych. Architektura sieci neuronowej została zaprojektowana z wykorzystaniem typowych zasad budowy sieci: jedna warstwa ukryta w przypadku średnio złożonych zadań klasyfikacji, liczba neuronów w warstwie wejściowej stanowiąca połowę liczby zmiennych w modelu, warstwa ukryta zawierająca liczbę neuronów stanowiących połowę liczby neuronów wejściowych i wyjściowych oraz jeden neuron w warstwie wyjściowej dla zadań klasyfikacji binarnej. Przeprowadzono próby oceny wpływu zwiększania oraz zmniejszania liczby neuronów w warstwach wejściowych i ukrytych na wyniki klasyfikacji. Nie przyniosło to pozytywnych rezultatów. Ostatecznie pozostawiono typową architekturę sieci neuronowej: warstwa wejściowa 130 neuronów, warstwa ukryta 70 neuronów z funkcją aktywacji ReLU oraz jeden neuron warstwy wyjściowej z sigmoidalną funkcją aktywacji, wielkość pliku wsadowego 128 obserwacji, 50 epok treningowych. Zwiększanie liczby epok nie przynosiło poprawy jakości modelu i wydłużało czas obliczeń. Duża liczba neuronów warstwy wejściowej, wynikająca z przekształcenia zmiennych kategoriycznych w zmienne dichotomiczne metodą One-Hot-Encoding spowodowała dużą liczbę nowych zmiennych binarnych.

Dokonano także doboru niektórych parametrów modelu, zmieniając współczynnik drop out pomiędzy warstwami od 0,2 do 0,6 oraz wagi klas w zmodyfikowanej metodzie uczenia, zaczynając od odwrotnej proporcji w stosunku do liczności klas i dochodząc do proporcji 2:1 przypisującej większą wagę błędnym klasyfikacjom klasy pozytywnej. Ostatecznie zastosowano współczynnik drop out równy 0,5 oraz wagi klas 2:1 jako parametry zapewniające najlepsze wyniki.

Badanie przeprowadzono dla tych technik under- i oversamplingu, które łącznie z czasem uczenia sieci neuronowej nie przekraczały jednej godziny czasu obliczeniowego. Zestawienie zastosowanych technik oraz wyniki jakości klasyfikacji przedstawione są w tabeli 4.6.

Uzyskane wyniki potwierdzają prostą prawidłowość – poprawa trafności klasyfikacji mniejszościowej klasy pozytywnej odbywa się zawsze kosztem trafności klasy większościowej i tym samym powoduje pogorszenie ogólnej trafności klasyfikacji modelu mierzonej wskaźnikiem *accuracy*. Najlepsze wyniki pod względem trafności klasyfikacji klasy pozytywnej, przy zachowaniu dobrej trafności ogólnej modelu, zapewniły metody losowego *undersamplingu* i *oversamplingu* połączone z metodą modyfikacji wagi klas w proporcji 2:1. Sztuczna sieć neuronowa przyniosła w większości przypadków lepsze wyniki mierzone parą wskaźników *sensitivity* SN i *accuracy* ACC w porównaniu z klasycznymi metodami uczenia maszynowego, z wyjątkiem metody *k*-najbliższych sąsiadów połączonej z techniką losowego *oversamplingu*. Jednakże niezwykle dobry wynik tej metody nasuwa przypuszczenie, że zbiór danych użytych w naszych badaniach był stworzony w wyniku zastosowania techniki *oversamplingu*. Wskaźnik F1-score i współczynnik korelacji Matthews’a MMC, uznawane zwykle za bardzo dobre miary oceny jakości klasyfikacji na danych niezbalansowanych, wydają się mało przydatne. Faworyzują ogólną trafność klasyfikacji kosztem klasyfikacji klasy pozytywnej – mniejszościowej. Może to prowadzić do dużych kosztów związanych z utratą środków pieniężnych przyznanych kredytobiorcy o wysokim ryzyku kredytowym, niewykrytym przed udzieleniem kredytu.

Tabela 4.6
Metryki klasyfikacji z użyciem sztucznej sieci neuronowej MLP

Metoda	ACC	SN	F1	MCC
Pierwotny zbiór	0,98	0,70	0,82	0,82
Oversampling losowy	0,94	0,77	0,68	0,66
Undersampling losowy	0,93	0,76	0,64	0,62
Pierwotny zbiór + wagi klas odwrotne do liczności klas	0,95	0,77	0,68	0,66
Pierwotny zbiór + wagi klas 2:1	0,98	0,69	0,82	0,82
Oversampling losowy + wagi klas 2:1	0,84	0,86	0,44	0,45
Undersampling losowy + wagi klas 2:1	0,83	0,86	0,43	0,44
Oversampling SMOTE	0,98	0,68	0,81	0,81
Oversampling SMOTE + wagi klas odwrotne do liczności klas	0,73	0,90	0,33	0,34
Oversampling SMOTE + wagi klas 2:1	0,97	0,70	0,77	0,76
Oversampling ROSE	0,98	0,68	0,81	0,81
Oversampling ADASYN	0,97	0,68	0,80	0,81
Oversampling Borderline SMOTE	0,97	0,70	0,79	0,78
Undersampling TomekLinks	0,98	0,68	0,81	0,81
Undersampling NearMiss-1	0,46	0,88	0,20	0,16

4.4. Wnioski i rekomendacje w procesie uczenia na zbiorach niezbalansowanych

Zagadnienie niezbalansowanych zbiorów danych w kontekście zastosowań uczenia maszynowego w praktyce gospodarczej, gdzie kluczowe zjawiska (np. niewypłacalność kredytobiorcy czy oszustwa finansowe) występują rzadko, ma bardzo istotne znaczenie w podejmowaniu decyzji. Dane niezbalansowane charakteryzują się dominacją jednej klasy, co utrudnia poprawną klasyfikację rzadkich, ale istotnych przypadków. Błędna klasyfikacja klasy mniejszościowej może generować wysokie koszty, a tradycyjne algorytmy nie radzą sobie z taką dysproporcją.

W badaniu zastosowano znane już rozwiązania tego problemu dzielące się na:

- zewnętrzne (modyfikacja danych): undersampling (np. Random, Tomek Links) i oversampling (np. SMOTE, ADASYN);
- wewnętrzne (modyfikacja algorytmów): zmiana wag klas, cost-sensitive learning;
- hybrydowe: łączące oba podejścia.

Do oceny modeli wykorzystano typowe miary jakości klasyfikacji, takie jak: czułość, F1-score, MCC i accuracy, przy czym największe znaczenie mają metryki ukierunkowane na klasę mniejszościową.

W badaniu wykorzystano rzeczywisty zbiór danych Loan Raw Data z LendingClub (ok. 887 tys. rekordów). Po odpowiednim preprocessingu danych zastosowano szereg metod uczenia maszynowego:

- klasyczne algorytmy: KNN, regresja logistyczna, drzewa decyzyjne, bagging, boosting;
- modyfikacje zbioru danych: random oversampling i undersampling, modyfikacja wag klas;
- sztuczne sieci neuronowe (MLP) z różnymi kombinacjami wag i metod oversamplingu (SMOTE, ADASYN, ROSE i inne).

Na podstawie przeprowadzonych badań empirycznych można przedstawić następujące wnioski.

- Najlepsze wyniki dla klasy mniejszościowej uzyskano przy użyciu drzew decyzyjnych, baggingu i metody KNN wraz z oversamplingiem, jednak tak wysoka skuteczność może budzić wątpliwości. Istnieje prawdopodobieństwo, że zbiór uczący został częściowo wygenerowany sztucznie przy użyciu metod oversamplingu, co mogło wpłynąć na zawyżenie metryk jakościowych.
- Random undersampling i oversampling poprawiły czułość kosztem ogólnej trafności (accuracy).
- Modyfikacja wag klas poprawia jakość klasyfikacji bez potrzeby zmiany zbioru danych.
- Najlepsze rezultaty przy użyciu sieci neuronowych uzyskano z wykorzystaniem nadpróbki metodą SMOTE i modyfikacją wag, choć żadna z metod nie okazała się idealna. Każde podejście wiązało się z kompromisami między dokładnością a czułością, a także czasem obliczeń.

W rozdziale przedstawiono kompleksową analizę metod i technik radzenia sobie z problemem niezbalansowanych danych, z praktycznym zastosowaniem w modelowaniu ryzyka

kredytowego. Warto jednak zaznaczyć, że zastosowane metody znacząco różnią się pod względem złożoności obliczeniowej oraz kosztów przetwarzania. Przykładowo, metody takie jak KNN czy oversampling (szczególnie SMOTE i ADASYN) wymagają znacznie większych zasobów obliczeniowych niż prostsze podejścia oparte na drzewach decyzyjnych i losowym usuwaniu obserwacji większościowych lub nadpróbkowaniu. W badaniu stwierdzono, że czas trenowania modelu KNN po oversamplingu losowym wyniósł nawet do czterech godzin, podczas gdy inne algorytmy, jak regresja logistyczna czy drzewa decyzyjne, potrzebowały poniżej 30 minut. Podobnie, metody takie jak SMOTE i ADASYN w połączeniu z siecią neuronową znacząco wydłużyły czas uczenia względem wersji bazowej. Metody, takie jak: Cluster Centroid Undersampling, Condenset Nearest Neighbourhood, czy NearMiss-3 wymagały znacznie większych zasobów obliczeniowych, niż były dostępne w trakcie badań. Złożoność obliczeniowa może być kluczowym czynnikiem przy wdrażaniu modeli w środowiskach produkcyjnych, zwłaszcza przy pracy z dużymi zbiorami danych.

5. Analiza i cyfrowe zarządzanie komunikacją w organizacji

5.1. Historia narzędzi zarządzania komunikacją interpersonalną

Współczesne organizacje funkcjonują w środowisku zdominowanym przez cyfrową komunikację. Pracownicy każdego dnia wymieniają setki e-maili, komunikatów na czatach czy wiadomości wideo. Według badania Gartnera (2023) aż 38% zatrudnionych czuje się przytłoczonych nadmiarem wewnętrznych komunikatów, który prowadzi do chaosu informacyjnego (Grensing-Pophal 2023). Jednocześnie rośnie świadomość znaczenia skutecznej komunikacji interpersonalnej dla sukcesu firmy – globalny rynek szkoleń z komunikacji miękkiej (interpersonalnej i międzykulturowej) ma wzrosnąć z około 23,6 mld USD w 2021 r. do ponad 47 mld USD w 2027 r. (BusinessWire 2022; Radicati Group 2023). Coraz częściej poszukuje się nowoczesnych rozwiązań, w tym sztucznej inteligencji (AI), w celu usprawnienia przepływu informacji i poprawy jakości interakcji w zespołach. AI potrafi już automatyzować tworzenie spersonalizowanych wiadomości e-mail czy powiadomień, tak by właściwe treści trafiały do odpowiednich osób (Grensing-Pophal 2023). Może także analizować ogromne wolumeny danych komunikacyjnych i na ich podstawie dostarczać użytecznych spostrzeżeń oraz prowadzić analizę nastrojów pracowników. W niniejszym rozdziale przedstawiono przegląd rozwoju narzędzi cyfrowej komunikacji w organizacjach oraz omówiono, jak narzędzia oparte na AI – na czele z systemem Empatyzer (Empatyzer 2025a) – mogą optymalizować komunikację i zarządzanie interakcjami międzyludzkimi.

Rozwój technologii informatycznych wywarł znaczący wpływ na komunikację interpersonalną w miejscu pracy. Początkowo komunikacja organizacyjna opierała się na tradycyjnych kanałach, takich jak bezpośrednie rozmowy, telefon oraz faks (Ou 2010; Turkle 2017). Do lat 80. XX wieku dominowały kontakty osobiste, a komunikacja pisemna realizowana była głównie drogą papierową lub za pośrednictwem faksów. Kanały te, choć efektywne na niewielką skalę, były niewystarczające wobec rosnącej złożoności oraz geograficznej ekspansji firm.

Przełomem była popularyzacja poczty elektronicznej, która od lat 90. szybko stała się dominującym medium komunikacji biznesowej (Dabbish i Kraut 2006). E-mail umożliwił niemal natychmiastową wymianę informacji, co przyspieszyło podejmowanie decyzji oraz poprawiło współpracę międzynarodową. Szacuje się, że każdego dnia wysyłanych i odbieranych jest ponad 370 mld e-maili (Ceci 2024), co obrazuje skalę cyfrowej wymiany informacji oraz potencjalne problemy, takie jak przeciążenie informacyjne czy chaos komunikacyjny (Dabbish i Kraut 2006; Radicati Group 2023).

Wraz z upowszechnieniem Internetu pojawiły się pierwsze intranety korporacyjne, które stanowiły wewnętrzną sieć informacyjną organizacji. Początkowo intranety były proste, służyły głównie publikacji dokumentów, ogłoszeń firmowych czy danych kontaktowych pracowników. Jednak szybko zaczęły ewoluować, wzbogacając się o narzędzia typu „groupware” – oprogramowanie grupowe, takie jak Lotus Notes (Coleman i Khanna 1995), które umożliwiały nie tylko przechowywanie informacji, ale również prowadzenie kalendarzy współdzielonych, wymianę dokumentów czy prowadzenie dyskusji zespołowych. To właśnie narzędzia „groupware” stworzyły podwaliny pod współczesne, złożone środowiska pracy zdalnej i hybrydowej.

Kolejnym etapem w historii cyfrowej komunikacji interpersonalnej było rozpowszechnienie się komunikatorów internetowych, które pod koniec lat 90. XX w. i na początku XXI w. weszły do codziennego użytku zarówno w środowisku domowym, jak i biznesowym. Popularność zyskały początkowo ogólne narzędzia, takie jak IRC (Internet Relay Chat) oraz ICQ, które umożliwiały prowadzenie rozmów tekstowych w czasie rzeczywistym. Następnie pojawiły się rozwiązania przeznaczone bezpośrednio dla biznesu, takie jak Microsoft Messenger (później Lync, a następnie Skype for Business) czy Cisco Jabber. Narzędzia te integrowały coraz więcej funkcjonalności – od prostych wiadomości tekstowych, przez połączenia głosowe, aż po wideokonferencje, które znacząco wzbogaciły komunikację zespołową.

W latach 2000. organizacje zaczęły dostrzegać znaczenie szerszego kontekstu społecznego w komunikacji wewnętrznej, co doprowadziło do pojawienia się platform określanych jako Enterprise Social Networks (ESN). Przykładem takich platform stały się Yammer czy Workplace by Facebook, które wzorując się na portalach społecznościowych, zaczęły budować społeczności wokół tematów, projektów i zespołów pracowniczych. ESN pozwoliły na swobodniejszą wymianę wiedzy, dzielenie się sukcesami i porażkami, zwiększenie transparentności działań organizacji oraz wzrost zaangażowania pracowników (Leonardi i in. 2013).

Dekada 2010–2020 przyniosła rozwój narzędzi do współpracy grupowej w czasie rzeczywistym, takich jak Slack, Microsoft Teams czy Google Workspace (Karl i in. 2022). Narzędzia te stanowią dziś centrum cyfrowego miejsca pracy, łącząc w jednym środowisku rozmowy tekstowe, wideokonferencje, współdzielenie plików oraz aplikacje zewnętrzne. Dzięki temu możliwe jest wykonywanie pracy niemal całkowicie zdalnie lub w modelu hybrydowym. Pandemia COVID-19 z lat 2020–2021 dodatkowo przyspieszyła wdrażanie tych rozwiązań, uświadamiając organizacjom konieczność posiadania elastycznych narzędzi do zarządzania pracą i komunikacją na odległość. Pracownicy często nie mają możliwości bezpośredniego spotkania, dlatego firmy inwestują w coraz doskonalsze technologie – od zaawansowanych systemów wideokonferencji po wirtualne przestrzenie robocze. W ostatnich latach obserwujemy też włączanie mechanizmów sztucznej inteligencji do narzędzi komunikacyjnych. Przykładowo, chatboty oparte na AI są wykorzystywane do udzielania pracownikom automatycznych odpowiedzi na często zadawane pytania oraz usprawniania procesów onboardingu (Grensing-Pophal 2023). Z kolei narzędzia analityczne potrafią monitorować przepływ komunikatów w organizacji, identyfikując wąskie gardła informacyjne czy kluczowe wskaźniki zaangażowania personelu.

Wraz z rosnącą rolą cyfrowej komunikacji pojawiły się nowe wyzwania związane z takimi problemami, jak przeładowanie informacyjne, syndrom ciągłej dostępności (always-on) czy

trudności w utrzymaniu relacji interpersonalnych w zespołach rozproszonych (Barley i in. 2011). W odpowiedzi na te problemy coraz częściej wykorzystywana jest sztuczna inteligencja (AI). Chatboty wspomagane przez AI stały się formą pierwszego kontaktu dla pracowników poszukujących informacji o procedurach, zasadach czy dokumentacji firmowej, redukując czas potrzebny na odpowiedzi działów HR. Zaawansowane algorytmy analityczne pozwalają monitorować przepływ informacji, identyfikować wąskie gardła komunikacyjne oraz analizować sentyment pracowników, co umożliwi szybkie reagowanie na problemy i zwiększa efektywność zespołów (Shukla i Dwivedi 2025).

Ważnym, choć niezwiązanym bezpośrednio z aspektami technicznymi, aspektem zarządzania komunikacją interpersonalną było wprowadzenie narzędzi psychometrycznych do oceny predyspozycji osobowościowych pracowników. Już w latach 60. XX w. środowiska biznesowe zaczęły stosować wskaźniki osobowości, takie jak MBTI (Myers-Briggs Type Indicator) czy kwestionariusze DISC, które pomagały lepiej zrozumieć różnice indywidualne między członkami zespołów. Testy te miały na celu poprawienie komunikacji interpersonalnej dzięki dostosowaniu stylów komunikacji do potrzeb poszczególnych pracowników. Jednak ich ograniczenia, takie jak niska stabilność wyników czy ograniczona wiarygodność psychometryczna wymusiły dalsze poszukiwania (Myers i in. 1985).

Od lat 80. XX w., dzięki opracowaniu modeli psychologicznych, takich jak Wielka Piątka (OCEAN) czy HEXACO podejście do diagnozy i rozwoju komunikacji interpersonalnej zyskało solidne podstawy empiryczne. Współczesne narzędzia psychometryczne, wspierane przez algorytmy AI (np. Empatyzer), pozwalają nie tylko precyzyjnie ocenić style komunikacyjne pracowników, ale również automatycznie sugerować najlepsze strategie interpersonalne, co znacząco poprawia jakość komunikacji oraz efektywność zespołów (Ashton i Lee 2007; Judge i in. 1999).

5.2. Model OCEAN i testy psychometryczne z wykorzystaniem metod AI

Współcześnie za naukowo ugruntowany standard opisu osobowości uznaje się pięcioczynnikowy model Wielkiej Piątki (Big Five), znany też jako akronim OCEAN od nazw następujących pięciu wymiarów: otwartość na doświadczenia (*Openness*), sumiennosc (*Conscientiousness*), ekstrawersja (*Extroversion*), ugodowość (*Amicability*) i neurotyczność (*Neuroticism*). Model ten wyłonił się nie z teorii, lecz z badań empirycznych – analizy języka i statystycznego grupowania cech. Już w latach 30. Gordon Allport i Henry Odbert dokonali pionierskiej analizy leksykalnej, wertując słowniki w poszukiwaniu słów opisujących cechy osobowości. W 1936 r. zidentyfikowali oni niemal 18 tys. takich terminów, które następnie skategoryzowali i zredukowali do około 4500 podstawowych deskryptorów cech (Misiuro 2017). Na tej bazie kolejni badacze (m.in. Raymond Cattell w latach 50.) stosowali analizę czynnikową, grupując cechy i tworząc bardziej zwarte modele – Cattell zaproponował 16 czynników osobowości (Cattell i Eber 1964). Ostatecznie w latach 80. niezależne badania Paula Costy i Roberta McCrae'a doprowadziły do wyłonienia pięciu powtarzalnych wymiarów

osobowości (McCrae i Costa 1989). Costa i McCrae opracowali kwestionariusz NEO-PI-R, który stał się jednym z głównych narzędzi pomiaru Wielkiej Piątki.

Model OCEAN okazał się użyteczny w różnych kontekstach – także biznesowych – ponieważ w zwięzły sposób opisuje stałe różnice indywidualne wpływające na style komunikacji, reakcje na stres, predyspozycje zespołowe itp. Co istotne, w przeciwieństwie do starszych podejść typologicznych (np. MBTI) model Wielkiej Piątki nie kategoryzuje ludzi według ustalonych typów, lecz traktuje cechy jako kontinuum. Dzięki temu testy oparte na OCEAN, takie jak NEO-FFI czy nowsze narzędzie B5T (Big Five Test), cechują się lepszą trafnością i rzetelnością pomiaru w porównaniu z testami typologicznymi (Dunn i in. 2014; Satow 2021). Dla porównania, popularny niegdyś wskaźnik MBTI pomija tak ważny wymiar jak neurotyczność i nie wykazuje zadowalającej powtarzalności wyników przy ponownym badaniu. Badania wskazują, że narzędzia typu MBTI często nie spełniają standardów naukowych – np. wielu autorów wprost określa je mianem „psychologicznej pseudonauki” (zob. Empatyzer 2025b). Podobne zastrzeżenia dotyczą innych uproszczonych testów osobowości wykorzystywanych w firmach, jak choćby popularny test czterech kolorów (profil Hartmana) czy kwestionariusz DISC. Test DISC, stworzony jeszcze w 1928 r., skupia się na łatwo dostrzegalnych zachowaniach, pomijając głębsze aspekty osobowości i brakuje mu ustandaryzowanych norm odniesienia – w efekcie dwie osoby z identycznym wynikiem mogą w praktyce funkcjonować zupełnie inaczej (Empatyzer 2025c). Co więcej, rozpowszechnienie DISC w rekrutacji doprowadziło do powstania szkoleń uczących kandydatów, „jak wypaść dobrze” w tym teście, co podważa szczerłość uzyskiwanych odpowiedzi (Empatyzer 2025d).

Wobec powyższych wyzwań kluczowe jest wykorzystanie testów opartych na rzetelnych modelach, jak właśnie Wielka Piątka. W ostatnich latach pojawiły się również nowe rozszerzenia modeli osobowości. Przykładowo model HEXACO dodaje do tradycyjnej Wielkiej Piątki szósty czynnik – *Honesty-Humility* (uczciwość/pokora). Choć HEXACO zyskał pewne poparcie, badania wykazały, że w praktyce wymiar „uczciwość/pokora” silnie koreluje z ugodowością, co podaje w wątpliwość zasadność wyodrębniania go jako odrębnej cechy (Ashton i Lee 2007; Empatyzer 2025e). Najnowsze podejścia starają się natomiast powiązać strukturę cech z podstawami neurologicznymi. W 2015 r. opracowano tzw. Cybernetyczną Wielką Piątkę (model BFAS/CB5T), która integruje wiedzę z psychologii i neurobiologii w opisie osobowości (Empatyzer 2025f). Modele te są rozwijane m.in. pod kątem lepszej zgodności z klasyfikacjami klinicznymi (np. modelami osobowości w DSM-5) oraz zastosowań w diagnozie zaburzeń (DeYoung 2015).

Istotnym trendem jest zastosowanie metod sztucznej inteligencji w obszarze testów psychometrycznych i analizy osobowości (Dennehy i in. 2022). AI znajduje zastosowanie na kilku płaszczyznach. Po pierwsze, umożliwia automatyzację przeprowadzania testów oraz inteligentną analizę odpowiedzi – np. algorytmy mogą dynamicznie dobierać pytania w zależności od wcześniejszych odpowiedzi (testowanie adaptatywne), skracając czas badania bez utraty dokładności. Po drugie, uczenie maszynowe pozwala przewidywać cechy osobowości na podstawie danych niebezpośrednich, takich jak aktywność w mediach społecznościowych czy nawet analiza języka tekstów pisanych przez daną osobę. Przykładem drugiego podejścia w tym zakresie są narzędzia oparte na wyszukiwaniu semantycznym z wykorzystaniem relacji słownikowych, przykładowo takich jak te rozwijane dla języka

polskiego z wykorzystaniem projektu WordNet (Cyrul i in. 2012; Potiopa i in. 2017), które umożliwiają bardziej złożoną i szczegółową eksplorację dokumentów tekstowych w dziedzinie prawnej. Opracowano również modele AI potrafiące z zaskakująco wysoką trafnością ocenić poziom ekstrawersji czy ugodowości użytkownika na podstawie jego wpisów na Twitterze (Mereu 2021). Eksperymenty poszły jeszcze dalej – wykazano, że głębokie sieci neuronowe są w stanie inferować rysy osobowości nawet z pojedynczej fotografii twarzy (Sussman 2025), co jednak budzi kontrowersje etyczne i naukowe. Niemniej takie badania pokazują potencjał AI w odkrywaniu subtelnych korelacji między zachowaniem (bądź jego cyfrowym śladem) a cechami osobowości.

5.3. Miary rzetelności testów psychometrycznych

Aby wyniki testów osobowości czy innych kwestionariuszy psychometrycznych mogły być użyteczne w praktyce zarządzania, muszą cechować się wysoką rzetelnością. Rzetelność testu odnosi się do precyzji i powtarzalności pomiaru – innymi słowy, na ile wyniki odzwierciedlają prawdziwe cechy osoby, a na ile są dziełem przypadku czy błędu. Jednym z najpopularniejszych wskaźników rzetelności jest współczynnik alfa Cronbacha (α), zaproponowany przez Lee Cronbacha w 1951 r. Alfa Cronbacha mierzy wewnętrzną spójność testu, czyli stopień, w jakim poszczególne pytania (pozycje testowe) mierzą te same konstrukty teoretyczne. Wartość α zawiera się między 0 a 1 – im wyższa, tym lepiej. Przyjmuje się, że minimalna akceptowalna rzetelność to około 0,7, choć w badaniach naukowych często wymaga się, aby wartość α była większa od 0,8 dla kluczowych skal (Pilarz 2025). W praktyce alfa Cronbacha bywa traktowana jako dolne oszacowanie rzetelności, ponieważ niespełnienie pewnych założeń (np. równoważności tau (τ) między pozycjami) może zaniżyć jej wartość (Hryniewicz 2025).

Innym współczynnikiem, coraz częściej zalecanym przez psychometrów, jest omega McDonalda (ω) (Jankowski 2025). Omega, zaproponowana przez McDonalda w 1999 r., opiera się na modelu czynnikowym i stanowi bardziej wiarygodne oszacowanie rzetelności, zwłaszcza gdy test nie jest jednorodny. W przeciwieństwie do alfy Cronbacha współczynnik omega McDonalda nie zakłada jednakowego udziału wszystkich składowych w ogólnym wyniku skali – pozwala uwzględnić różnice w sile związku poszczególnych pytań z mierzonym czynnikiem. Omega zakłada istnienie jednego ukrytego czynnika (np. cechy osobowości) tłumaczącego odpowiedzi i estymuje proporcję wariancji wyników, jaką ten czynnik wyjaśnia (IBM SPSS 2025). Omega McDonalda uznawana jest za bardziej stabilną od alfy Cronbacha miarę rzetelności w sytuacjach, gdy skalę testu tworzą niejednorodne składowe lub gdy liczba pytań jest niewielka (Dunn i in. 2014).

W literaturze sugeruje się, by raportować obie miary – α i ω – dla pełniejszego obrazu jakości testu. Przykładowo, jeśli kwestionariusz uzyskał α Cronbacha = 0,85 i równocześnie ω = 0,86, wskazuje to na bardzo dobrą spójność wewnętrzną narzędzia. Gdyby natomiast α istotnie odbiegała od ω (np. α = 0,60 przy ω = 0,80), mogłoby to sugerować naruszenie założeń klasycznego modelu i potrzebę dokładniejszej analizy struktury testu (Peters 2014; Zinbarg i in. 2005).

Warto wspomnieć, że oceniając rzetelność testów osobowości, należy brać pod uwagę również inne czynniki. Jednym z problemów jest podatność na odpowiedzi zgodne z oczekiwaniami społecznymi, potocznie zwana „efektem wybielania” cech. Osoby badane mogą nieświadomie lub celowo udzielać odpowiedzi przedstawiających ich w lepszym świetle, co zafałszowuje wyniki. Dlatego profesjonalne testy często zawierają skale kontrolne wykrywające takie tendencje (np. skale szczerości). Innym aspektem jest stabilność czasowa wyników – dobry test powinien dawać zbliżone rezultaty przy powtórnym badaniu tej samej osoby po pewnym czasie (o ile nie zaszła rzeczywista zmiana cechy). To tzw. rzetelność test-retest, której miarą jest korelacja wyników z dwóch pomiarów. Wszystkie te wskaźniki łącznie pozwalają ocenić, czy dany test psychometryczny nadaje się do zastosowań praktycznych, np. w doradztwie personalnym czy programach rozwoju kompetencji w organizacji.

5.4 Optymalizacja komunikacji w organizacji za pomocą AI

Sztuczna inteligencja otwiera nowe możliwości w usprawnianiu komunikacji wewnątrz organizacji, wychodząc poza tradycyjne szkolenia i uniwersalne poradniki komunikacyjne. Jednym z pionierskich rozwiązań jest system Empatyzer – wirtualny trener komunikacji, który personalizuje wskazówki dla pracowników na podstawie ich profilu psychologicznego. Empatyzer z naukową precyzją rozpoznaje różnice osobowościowe i kulturowe między pracownikami, a następnie podpowiada im, jak skutecznie rozmawiać ze sobą (zob. Empatyzer 2025g). Jest to pierwszy na świecie wirtualny trener komunikacji dla firm, rozwijany w formie usługi SaaS (Software-as-a-Service) – powstał w Krakowie i został zaprojektowany jako narzędzie wspierające programy Diversity & Inclusion dzięki lepszemu wykorzystaniu różnorodności zespołu (Grensing-Pophal 2023).

Działanie Empatyzera opiera się na wcześniej omówionych testach psychometrycznych. Użytkownicy (pracownicy) na wstępie wypełniają naukowo zweryfikowany kwestionariusz osobowości (oparty na modelu Wielkiej Piątki) oraz test preferencji międzykulturowych. Wyniki tych testów pozostają poufne – zna je wyłącznie sam pracownik oraz system AI. Na podstawie różnic w profilach dwóch osób Empatyzer potrafi identyfikować potencjalne źródła nieporozumień w komunikacji – wynikające np. z odmiennego stylu pracy, różnego poziomu bezpośredniości czy innych oczekiwań co do formalności rozmowy. Następnie, tuż przed zaplanowaną interakcją (np. spotkaniem online lub rozmową przez komunikator), narzędzie dostarcza każdemu z uczestników spersonalizowane wskazówki komunikacyjne (rys. 5.1).

I tak, rozmówca osoby o profilu zbliżonym do „Wojtka” – z naszego przykładu (osoby niecierplivej, nastawionej na cel i konkrety) otrzyma rekomendację, by komunikować się z nim krótko, rzeczowo i oficjalnie, szybko przechodząc do sedna sprawy. Z kolei rozmówcy osoby o profilu zbliżonym do „Ani” (osoby towarzyskiej, wrażliwej na relacje) Empatyzer zasugeruje rozpoczęcie rozmowy od uprzejmego pytania o samopoczucie, spokojny ton bez okazywania zniecierpliwienia oraz dokładne instrukcje w razie delegowania zadań (rys. 5.2).

Takie drobne dostosowania języka i stylu mogą znacząco poprawić wzajemne zrozumienie i komfort rozmowy.



Rys. 5.1. Porady wygenerowane dla osoby komunikującej się z „Wojtkiem” w systemie Empatyzer
 źródło: empatyzer.com



Rys. 5.2. Porady wygenerowane dla osoby komunikującej się z „Anią” w systemie Empatyzer
 źródło: empatyzer.com

Empatyzer działa zatem jak osobisty coach komunikacji dostępny na wyciągnięcie ręki przed każdą ważną interakcją. Dzięki temu może wyeliminować wiele typowych problemów wynikających z nieodpowiedniego zarządzania różnorodnością w zespole. Tam, gdzie tradycyjne szkolenia bywają kosztowne i krótkotrwałe, AI oferuje ciągle wsparcie i natychmiastowe porady dostosowane do kontekstu i konkretnych osób. Jest to szczególnie cenne w realiach pracy zdalnej i hybrydowej, gdzie brak bezpośredniego kontaktu utrudnia budowanie relacji – w takich sytuacjach Empatyzer pomaga „przetłumaczyć” style komunikacyjne na język zrozumiały dla obu stron dialogu.

Oprócz Empatyzera istnieją też inne zastosowania AI usprawniające komunikację organizacyjną. Przykładowo, narzędzia oparte na generatywnej AI (jak modele typu ChatGPT) są używane do tworzenia szkiców wiadomości do pracowników lub podsumowań długich wątków dyskusji, tym samym oszczędzając menedżerom czas i pracę (Grensing-Pophal 2023). Analiza sentymentu przy użyciu uczenia maszynowego pozwala działom HR monitorować nastroje załogi – dzięki analizie tysięcy komunikatów zwrotnych, ankiet czy wypowiedzi na wewnętrznych forach AI potrafi wychwycić dominujące emocje i obawy pracowników. Chatboty wewnętrzne nie tylko udzielają odpowiedzi w systemie 24/7 na pytania (np. o procedury HR), ale także personalizują komunikację – mogą np. przypominać pracownikowi o zaległym szkoleniu w preferowany przez niego sposób (mail, SMS itp.) lub pomóc nowej osobie w firmie zapoznać się z kulturą organizacji. Wreszcie AI znajduje zastosowanie w tłumaczeniu maszynowym – globalne korporacje korzystają z algorytmów tłumaczących w czasie rzeczywistym treści komunikatów firmowych na wiele języków, co ułatwia współpracę wielonarodowych zespołów (Grensing-Pophal 2023).

Jak widać, historia zarządzania komunikacją interpersonalną pokazuje ewolucję od prostych, analogowych metod do zaawansowanych narzędzi cyfrowych i sztucznej inteligencji. Każdy kolejny etap rozwoju technologii informatycznych stawiał przed organizacjami nowe wyzwania, ale także otwierał nowe możliwości usprawniania relacji interpersonalnych, które pozostają kluczowe dla sukcesu współczesnych przedsiębiorstw. Rozwój sztucznej inteligencji wyraźnie wpływa na systemy informatyczne zarządzania komunikacją w organizacjach. Sztuczna inteligencja umożliwia zarówno dokładniejsze rozpoznanie uwarunkowań ludzkich działań (dzięki analizie osobowości i dostosowaniu formy przekazu), jak i usprawnienie technicznej strony dystrybucji informacji (dzięki automatyzacji i personalizacji). Przedsiębiorstwa, które potrafią skutecznie zaadaptować narzędzia AI do zarządzania komunikacją, zyskują bardziej zgraną i efektywną kadre, przyczyniającą się do wzrostu innowacyjności i lepszych wyników biznesowych organizacji. Dzięki umiejętnemu połączeniu wiedzy z psychologii (jak model OCEAN) z nowoczesnymi technologiami (jak Empatyzer czy chatboty HR) komunikacja staje się nie obciążeniem, a katalizatorem rozwoju organizacji.

6. Zarządzanie procesem ładowania pojazdu elektrycznego z użyciem elementów technologii blockchain

6.1. Elektromobilność i blockchain

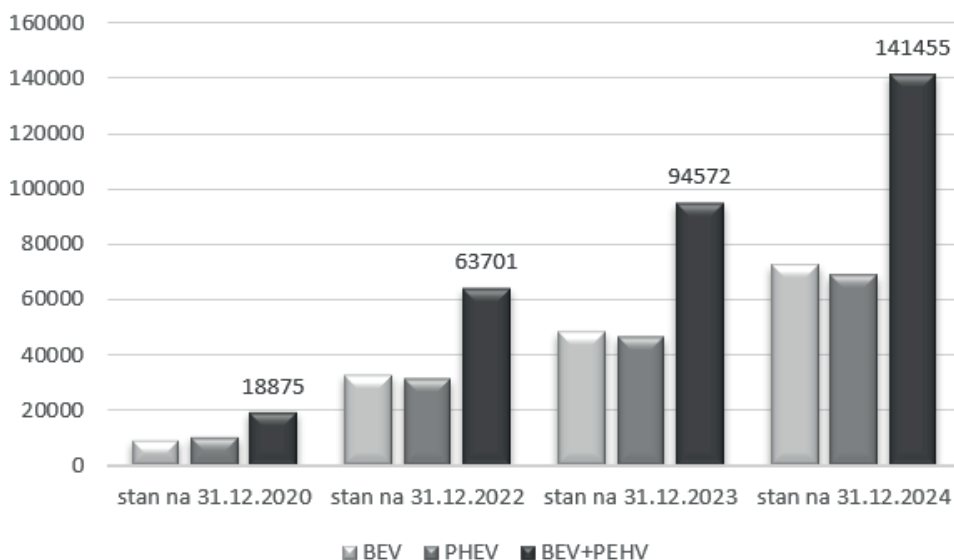
Energia elektryczna jest produktem, który stanowi przedmiot handlu na konkurencyjnym rynku energii. Tak jak każdy inny towar energia elektryczna musi zostać wyprodukowana, następnie jest sprzedawana i dostarczana odbiorcom końcowym, tj. klientom indywidualnym, firmom i instytucjom. Sprzedaż i dostawa energii zazwyczaj toczą się z udziałem operatorów systemów sieciowych oraz pośredników, którzy umożliwiają zaspokajanie potrzeb elektroenergetycznych podmiotów zainteresowanych zakupem energii. W procesy te zaangażowane są tysiące ludzi, systemy komputerowe, platformy rozliczeniowe czy banki. Energia podlega m.in. rozliczeniom związanym z ładowaniem pojazdów elektrycznych, a ściślej – z ładowaniem pojazdów elektrycznych z wykorzystaniem środowiska, jakim jest blockchain. Blockchain to architektura przechowywania informacji w sposób gwarantujący niezmiennosc danych historycznych. Blockchain to m.in. zdecentralizowana (bez centralnych jednostek zarządzających) i rozproszona baza danych lub rejestr transakcji lub zdarzeń, funkcjonujące jako rosnąca jednokierunkowa lista rekordów zwanych blokami, mających łącza do bloków poprzednich, utworzonych z użyciem funkcji kryptograficznych oraz znaczników czasu. Architektura przechowuje dane (tu: ilość energii elektrycznej, zapisy księgowo) zakodowane za pomocą algorytmów kryptograficznych (Zielińska 2021), działających według wcześniej ustalonych zasad, tzw. inteligentnych kontraktów (smart contract), czyli zbioru przepisów dotyczących funkcjonowania (protokołu) danej cyfrowej umowy, jej automatycznej weryfikacji (osiągnięcia konsensusu), egzekwowania negocjacji lub dokumentowania prawnego jej istotnych zdarzeń zgodnie z warunkami tejże umowy.

Integracja zagadnień dotyczących zakupu i zarządzania energią elektryczną z technologią blockchain otwiera nowe możliwości synergii pomiędzy naukami o zarządzaniu a sektorem technologii informacyjnych. Technologia blockchain to możliwość wspierania procesu rozliczania, bilansowania i przepływu energii elektrycznej, działań mających istotne znaczenie w trendach światowego rozwoju w branży energetyki. Gospodarka energią elektryczną, odczyty parametrów energii, wartości mocy, wartości skuteczne napięcia i natężenia to pojęcia odnoszące się do prowadzenia efektywnej polityki wykorzystywania energii elektrycznej, które – podobnie jak wiele innych – wpisują się na stałe w istotę elektromobilności oraz rozliczania procesów ładowania pojazdów elektrycznych.

Obecnie można wskazać wiele zalet oraz możliwości zastosowania technologii blockchain w różnych obszarach i sektorach gospodarki związanej z handlem i obrotem energią

elektryczną. Opierając się na studiach literaturowych, skoncentrowano się na możliwości zastosowania rozwiązań bazujących na technologii blockchain w procesie rozliczania ładowania pojazdów elektrycznych oraz analizie tych zastosowań jako prognoz dalszego rozwoju.

Na rynku energii elektrycznej i rozwijającym się rynku pojazdów elektrycznych (EV) zachodzą wielkie zmiany. Z roku na rok rośnie liczba samochodów z napędem elektrycznym, są one również coraz tańsze, a tym samym coraz bardziej dostępne dla kierowców. Na koniec grudnia 2024 r. w Polsce było zarejestrowanych 80 699 szt. osobowych i użytkowych aut całkowicie elektrycznych (BEV, *battery electric vehicles*). Przez 12 miesięcy ub.r. ich liczba wzrosła o 24 223 szt. Jak podały Polski Związek Przemysłu Motoryzacyjnego (PZPM) i Polskie Stowarzyszenie Nowej Mobilności (PSNM), pod koniec grudnia 2024 r. po polskich drogach jeździło 141 455 samochodów osobowych z napędem elektrycznym. Flota w pełni elektrycznych, osobowych aut liczyła 72 589 szt., a park hybryd typu plug-in (PHEV, *plug-in hybrid electric vehicles*) 68 866 szt. (rys. 6.1) (Licznik Elektromobilności I 2025).

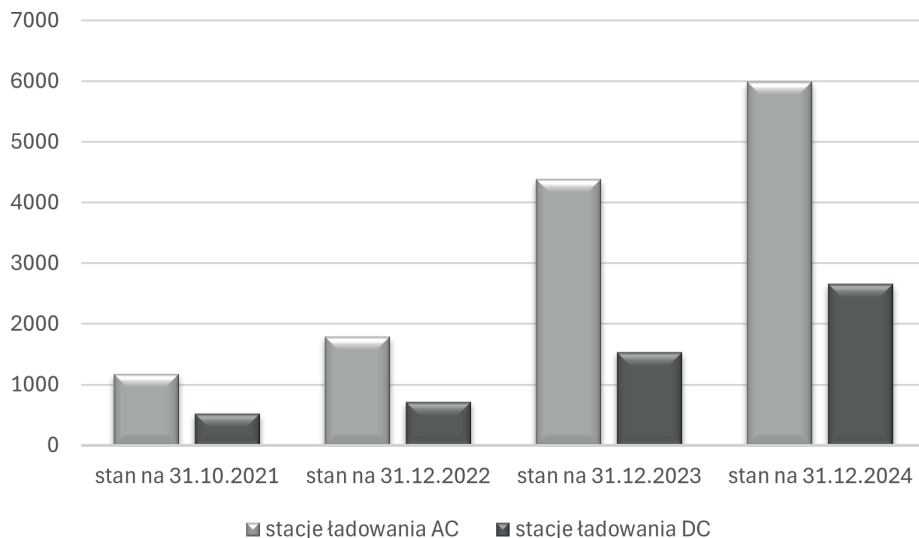


Rys. 6.1. Przyrost liczby osobowych pojazdów elektrycznych w Polsce [szt.]

Źródło: (Licznik Elektromobilności I 2025; Licznik Elektromobilności II 2025; Licznik Elektromobilności III 2025)

Na koniec 2024 r. liczba samochodów dostawczych i ciężarowych z napędem elektrycznym wynosiła 8143. Stale rosła też flota elektrycznych motorowerów i motocykli, która na koniec grudnia liczyła 23 456 szt., a także liczba osobowych i dostawczych aut hybrydowych, która powiększyła się do 954 340 szt. Pod koniec ubiegłego roku park autobusów zeroemisyjnych w Polsce wzrósł do 1472 szt.; z tego pojazdy całkowicie elektryczne stanowiły 1385 szt., zaś wodorowe 87 szt. Jak podaje źródło (Licznik elektromobilności I 2025), pod koniec 2024 r. w Polsce funkcjonowało 8659 ogólnodostępnych punktów ładowania pojazdów

elektrycznych – 31% z nich stanowiły szybkie punkty ładowania prądem stałym (DC), a 69% wolne punkty prądu przemiennego (AC) o mocy mniejszej lub równej 22 kW (rys. 6.2).



Rys. 6.2. Punkty ładowania pojazdów elektrycznych w Polsce [szt.]

Źródło: (Licznik Elektromobilności I 2025; Licznik Elektromobilności II 2025; Licznik Elektromobilności III 2025)

W tym właśnie sektorze rynku, tj. elektromobilności, mogą być wykorzystane rozwiązania blockchaina, co zapewni mu przewagę nad obecnymi standardami rozliczania procesu ładowania. Zarządzanie procesem ładowania i rozliczaniem ilości pobranej w nim energii wydaje się idealnym połączeniem technologii. Struktura blockchaina zapewnia zgodność zapisów transakcji, gwarantowaną przez wspomniany smart contract, czyli inaczej kod komputerowy zawierający zestaw reguł biznesowych, na które umówiły się strony zawierające kontrakt. Smart contract zapisywany jest na blockchainie, więc nie może być zmieniony lub odwołany. Kiedy spełnione zostaną ustalone wcześniej warunki (np. ceny), kontrakt jest automatycznie i nieodwołalnie wykonany. Mechanizm ten obejmuje aktywa cyfrowe i co najmniej dwie strony transakcji. Właśnie do takiej transakcji dochodzi podczas procesu ładowania pojazdu elektrycznego. W momencie podłączenia pojazdu do ładowarki użytkownik EV, zgadzając się na warunki ładowania (m.in. cenę energii), inicjuje zawarcie inteligentnego kontaktu. Zazwyczaj płatność za taki proces, realizowana jest gotówką, kartą, a także np. tokenami czy żetonami (inaczej voucherami) uprawniającymi do obniżki ceny energii dostępnej w ładowarce. Cały proces pod względem przepływu energii elektrycznej, zarówno tej do użytkownika EV, jak i tej do ładowarki w sieci elektroenergetycznej, zapisywany jest w blokach i rozliczany według przyjętych w kontrakcie zasad. Możliwość rezygnacji z centralnego pośrednika takiej transakcji zapewnia stronom procesu wysoki poziom zaufania do integralności danych i transparentności przepływów finansowych.

Zastosowana technologia blockchain w rozliczaniu procesu ładowania EV odbywa się za pośrednictwem stacji ładowania wyposażonej w system oparty na idei inteligentnych kontraktów. Rozwiązanie to zapewnia poprawność całego procesu oraz umożliwia rejestrowanie danych dotyczących zużycia energii i rozliczeń finansowych w łańcuchu bloków. Taki zapis gwarantuje niezmiennosc danych, przejrzystosc procesu i transparentność rozliczeń.

Jak podają źródła (Laarabi i in. 2020; Mohanta i in. 2019; Zielińska 2020), możliwości rozwijania technologii blockchain i inteligentnych kontraktów jest bardzo wiele. Pozostają one jednak częstym tematem dyskusji naukowych prowadzonych przez informatyków. Ze względu na dynamiczny charakter kodów i algorytmów inteligentne kontrakty muszą być znacznie bardziej elastyczne, responsywne i możliwe do kontroli. Konieczność rozwiązań legislacyjnych dotyczących bezpieczeństwa technologii może negatywnie wpływać na rozwój inteligentnych kontraktów.

Zastosowanie technologii blockchain do rejestrowania informacji o procesie ładowania pojazdów elektrycznych stanowi odpowiedź na rosnącą popularność elektromobilności oraz związane z nią wyzwania dla systemu elektroenergetycznego, opisane w niniejszym rozdziale. Jak wskazują spółki elektroenergetyczne, dynamiczny rozwój elektromobilności – szczególnie w sektorze pojazdów prywatnych – może znacząco obciążać sieci dystrybucyjne, jeśli ładowanie nie będzie właściwie zarządzane (Licznik Elektromobilności I 2025; Licznik Elektromobilności II 2025; Licznik Elektromobilności III 2025). Wprowadzenie blockchaina pozwala więc nie tylko na precyzyjne monitorowanie i rozliczanie zużycia energii w czasie rzeczywistym, ale także na automatyzację procesu.

Jak podaje źródło (Nour i in. 2019), blockchain można wykorzystać do zarządzania techniką inteligentnego ładowania dla EV. Przy użyciu sterownika z logiką rozmytą, opisanego jako smart contract, możliwe jest zarządzanie procesem ładowania pojazdu elektrycznego w taki sposób, aby zmaksymalizować korzyści dla dostawcy energii elektrycznej i właściciela pojazdu elektrycznego. Korzyścią dla zakładu energetycznego jest złagodzenie wpływu ładowania EV na sieć dystrybucyjną dzięki ładowaniu EV w okresie poza szczytem, a korzyścią dla właścicieli EV jest ładowanie pojazdu po niskich kosztach. Sterownik reguluje i steruje mocą ładowania w zależności od sygnału ceny energii elektrycznej dostarczanego przez zakład energetyczny oraz stanu naładowania akumulatora EV. Przy użyciu modelu sterownika opisanego w pracy wykazano, że wpływ inteligentnego ładowania pojazdów elektrycznych na sieć dystrybucyjną jest mniejszy w porównaniu z wpływem ładowania niekontrolowanego.

Na podstawie opisu inteligentnych kontraktów przedstawionego w poprzedniej części rozdziału można stwierdzić, że w niektórych przypadkach tego rodzaju rozwiązania mogą tworzyć wiążące prawa i obowiązki dla stron. Mechanizm działania inteligentnych kontraktów najlepiej oddaje analogia do automatu sprzedającego – gdzie złożenie oferty i jej przyjęcie następuje w wyniku automatycznego wykonania czynności, bez potrzeby dodatkowej interwencji człowieka. Podobnie działa proces sprzedaży energii elektrycznej w ramach ładowania pojazdu elektrycznego – wykonanie zobowiązań umownych odbywa się automatycznie, zgodnie z wcześniej zdefiniowanymi warunkami zapisanymi w kodzie.

Inteligentne kontrakty stanowią przykład nowoczesnych praktyk umownych opartych na technologii, które firmy i decydenci powinni zacząć uwzględniać z odpowiednim

wyprzedzeniem. Mimo to, ze względu na wciąż ograniczony stopień dojrzałości tej technologii, liczba realnych zastosowań jest obecnie dość ograniczona. Dalszy rozwój inteligentnych kontraktów będzie wymagać zintegrowanego podejścia łączącego aspekty technologiczne, ekonomiczne, prawne oraz społeczne.

Pojęciem szeroko wykorzystywanym w technologii blockchain jest tokenizacja. Jest to proces, w którym energię elektryczną można zaprezentować jako jednostki wartości. Dzięki temu można przypisać im konkretne wartości energetyczne jako cyfrowym aktywom, umożliwiając ich łatwą wymianę, przechowywanie i sprzedaż. Tokenizacja energii może być szczególnie korzystna dla operatorów stacji ładowania, użytkowników EV oraz dostawców energii odnawialnej. Do głównych zalet tokenizacji energii elektrycznej w procesie ładowania pojazdów elektrycznych należy m.in. łatwiejsze śledzenie źródła pochodzenia energii – użytkownicy mogą sprawdzić, czy energia pochodzi np. z odnawialnych źródeł. Kolejną korzyścią jest eliminacja pośredników – transakcje mogą być realizowane bez udziału tradycyjnych dostawców energii. Istotną zaletą jest także możliwość handlu tokenizowaną energią, co umożliwia użytkownikom jej kupno i sprzedaż, wspierając tym samym rozwój zdecentralizowanego rynku energetycznego (Zielińska 2019).

Aby móc rozliczać proces ładowania EV z wykorzystaniem technologii blockchain, istotne jest zapoznanie się z ideą inteligentnego kontraktu (smart contracts) – są to programy komputerowe przechowywane w blockchainie, które automatycznie wykonują określone operacje, gdy spełnione zostaną zdefiniowane warunki. W systemach ładowania EV mogą być wykorzystywane do automatyzacji procesów rozliczeniowych między użytkownikami a operatorami stacji. Korzyściami wynikającymi z użycia inteligentnych kontraktów są: brak konieczności ręcznego przetwarzania płatności – transakcje są automatyczne i szybkie, zwiększone bezpieczeństwo – kontrakty eliminują ryzyko oszustw i błędów ludzkich, oraz niższe koszty operacyjne z uwagi na brak pośredników i związane z tym niższe opłaty transakcyjne.

Przykładowy przebieg transakcji opartej na inteligentnym kontrakcie może wyglądać następująco:

1. Kierowca EV podłącza pojazd do stacji ładowania.
2. Stacja wysyła żądanie do blockchaina w celu autoryzacji transakcji.
3. Inteligentny kontrakt sprawdza, czy użytkownik ma wystarczające środki (np. tokeny energetyczne) do opłacenia usługi.
4. Po zakończeniu ładowania kontrakt automatycznie przekazuje odpowiednią płatność na konto operatora.
5. Użytkownik otrzymuje potwierdzenie transakcji w sposób transparentny i niezmienny.

Aby taki proces mógł się wydarzyć, potrzebne jest pokonanie kilku wyznań, jakie niosą ze sobą głównie regulacje prawne, ponieważ w wielu krajach przepisy dotyczące blockchaina i tokenizacji energii są jeszcze niejasne. Dużym wyzwaniem w tego typu rozwiązaniach jest integracja inteligentnych kontraktów z istniejącą infrastrukturą – wiele systemów ładowania EV działa na podstawie tradycyjnych systemów płatności i wymaga adaptacji do blockchaina. Istotnym ograniczeniem dla takiego rozwiązania jest również problem skalowalności, ponieważ blockchain musi obsługiwać dużą liczbę transakcji w czasie rzeczywistym – dlatego konieczna jest optymalizacja technologii.

Wprowadzenie blockchaina do systemów ładowania EV może zrewolucjonizować sposób, w jaki użytkownicy rozliczają się za energię. Tokenizacja energii, inteligentne kontrakty oraz kryptowaluty otwierają tym samym nowe możliwości dla bardziej zdecentralizowanego i efektywnego rynku energetycznego. Mimo pewnych wyzwań technologicznych i regulacyjnych rozwój blockchaina w tym sektorze może przyczynić się do zwiększenia dostępności i przejrzystości systemów ładowania pojazdów elektrycznych, wspierając jednocześnie zrównoważony rozwój i integrację z odnawialnymi źródłami energii.

6.2. Wpływ technologii blockchain na rozwój infrastruktury ładowania EV

Rzeczony infrastruktury ładowania pojazdów elektrycznych stanowi jedno z kluczowych wyzwań dla sektora elektromobilności. Wraz ze wzrostem liczby użytkowników pojazdów elektrycznych (EV) konieczne staje się stworzenie wydajnego, powszechnie dostępnego i elastycznego systemu ładowania, zdolnego do zaspokojenia rosnącego zapotrzebowania na energię w tym procesie. Technologia blockchain może odegrać istotną rolę w usprawnieniu i optymalizacji zarządzania stacjami ładowania, a także przyczynić się do zwiększenia transparentności i demokratyzacji dostępu do infrastruktury.

Technologia blockchain umożliwia eliminację pośredników z procesu ładowania, co znacząco upraszcza zarządzanie punktami i stacjami ładowania. Pozwala także na automatyzację kluczowych funkcji, takich jak monitorowanie dostępności stacji, dynamiczne dostosowywanie cen do poziomu popytu oraz optymalizację planowania tras dojazdu do ładowarek dzięki dostępowi do danych w czasie rzeczywistym (np. dane GPS). Zastosowanie inteligentnych kontraktów umożliwia pełną automatyzację procesu płatności, a także eliminuje opóźnienia i problemy wynikające z braku interoperacyjności między systemami rozliczeniowymi różnych operatorów.

Blockchain może również wspierać rozwój zdecentralizowanych modeli udostępniania infrastruktury. Prywatni właściciele punktów ładowania mogliby dzielić się swoją infrastrukturą z innymi użytkownikami za pośrednictwem bezpiecznej i przejrzystej platformy. Taki model pozwalałby na efektywniejsze wykorzystanie istniejących punktów ładowania oraz zwiększenie ich dostępności bez konieczności ponoszenia kosztów budowy nowych stacji przez operatorów.

Integracja technologii blockchain z infrastrukturą ładowania otwiera także możliwość efektywnego zarządzania zużyciem energii. Rozproszone rejestry umożliwiają monitorowanie źródła pochodzenia energii dostarczanej do stacji, co ma istotne znaczenie w kontekście realizacji celów zeroemisyjności. Inteligentne kontrakty mogą sterować procesem ładowania w taki sposób, by preferencyjnie wykorzystywać energię pochodzącą z odnawialnych źródeł, a także uwzględniać obciążenie sieci, uruchamiając ładowanie w godzinach najmniejszego zapotrzebowania na energię.

Technologia blockchain wspiera także rozwój systemów magazynowania energii wykorzystywanych w infrastrukturze ładowania EV. Integracja z akumulatorami oraz inteligentnymi sieciami (Smart Grids) umożliwia efektywne zarządzanie przepływami energii oraz

jej zużyciem. Użytkownicy dzięki dostępowi do danych zapisanych w rejestrach łańcucha blockchain mogą monitorować sposób wykorzystania energii w poszczególnych stacjach, co sprzyja tworzeniu bardziej zrównoważonych i zoptymalizowanych strategii zarządzania systemem energetycznym.

Wdrożenie technologii blockchain w infrastrukturze ładowania pojazdów elektrycznych wiąże się jednak z wyzwaniami natury technicznej i regulacyjnej. Konieczne jest opracowanie standardów protokołów komunikacyjnych oraz zapewnienie zgodności zapisu danych z obowiązującymi przepisami prawa. Dodatkowo systemy oparte na rozproszonych rejestrach muszą być odpowiednio skalowalne, aby móc obsługiwać rosnącą liczbę użytkowników i transakcji bez obniżania wydajności operacyjnej.

W perspektywie rozwoju inteligentnych sieci energetycznych technologia blockchain może stać się ich integralnym elementem, umożliwiając optymalizację i pełną automatyzację infrastruktury ładowania. W miarę postępu technologicznego oraz obniżania kosztów wdrażania tej technologii w sektorze energetycznym można oczekiwać, że jej wpływ na rozwój elektromobilności będzie coraz bardziej znaczący. Blockchain umożliwia nie tylko usprawnienie istniejących procesów, lecz także tworzenie innowacyjnych modeli biznesowych, które mogą przyczynić się do przyspieszenia transformacji transportu w kierunku bardziej zrównoważonej mobilności (Zielińska 2021).

6.3. Bezpieczeństwo danych i prywatność użytkowników w systemach blockchain dla EV

Wraz ze wzrostem liczby pojazdów elektrycznych oraz rosnącym znaczeniem systemów zarządzania energią opartych na technologii blockchain pojawiają się istotne wyzwania związane z bezpieczeństwem danych i ochroną prywatności użytkowników. Wprowadzenie zdecentralizowanych rejestrów transakcji, choć zapewnia przejrzystość i odporność na manipulacje, rodzi jednocześnie pytania dotyczące ochrony wrażliwych informacji, takich jak dane osobowe kierowców, historie ładowania czy lokalizacja pojazdów.

Jednym z kluczowych aspektów bezpieczeństwa technologii blockchain w ekosystemie pojazdów elektrycznych oraz szerzej – w sektorze elektromobilności – jest ochrona prywatności użytkowników. W tradycyjnych, scentralizowanych systemach dane są przechowywane na serwerach firm obsługujących infrastrukturę ładowania, co czyni je podatne na cyberataki i nieautoryzowany dostęp. Blockchain eliminuje pośredników (z wyjątkiem blockchainów prywatnych) i wykorzystuje mechanizmy kryptograficzne, umożliwiając użytkownikom większą kontrolę nad własnymi danymi. Niemniej jednak istnieją obawy, że publiczne łańcuchy bloków, które pozwalają na wgląd w zapisane transakcje, mogą prowadzić do ujawnienia informacji umożliwiających identyfikację konkretnych osób (Niedopytański 2024).

W odpowiedzi na te wyzwania coraz częściej stosuje się technologie zwiększające anonimowość transakcji, takie jak podpisy pierścieniowe, zero-knowledge proofs (ZKP) czy prywatne blockchajny. Podpisy pierścieniowe umożliwiają zatwierdzanie transakcji bez ujawniania tożsamości konkretnego użytkownika, natomiast protokoły ZKP pozwalają na weryfikację danych bez ich bezpośredniego ujawniania. Prywatne łańcuchy bloków ograniczają

z kolei dostęp do danych wyłącznie dla uprawnionych podmiotów, minimalizując tym samym ryzyko naruszenia prywatności.

Kolejnym wyzwaniem związanym z bezpieczeństwem systemów blockchain jest ich odporność na ataki hakerskie. Mimo że technologia ta jest uznawana za jedną z najbezpieczniejszych metod przechowywania danych, nie jest całkowicie wolna od zagrożeń. Jednym z najpoważniejszych jest tzw. atak 51%, który daje możliwość manipulowania transakcjami lub kradzieży kluczy prywatnych użytkowników. Choć takie przypadki są rzadkie, to w celu zwiększenia bezpieczeństwa wdrażane są wielopoziomowe mechanizmy uwierzytelniania, takie jak transakcje wielopodpisowe oraz sprzętowe portfele służące do zabezpieczania kluczy kryptograficznych.

W kontekście regulacji prawnych wdrażanie technologii blockchain w sektorze elektromobilności musi uwzględniać obowiązujące przepisy dotyczące ochrony danych, takie jak RODO (Rozporządzenie o Ochronie Danych Osobowych, UE) czy CCPA (California Consumer Privacy Act, USA). Jednym z głównych problemów jest niezmiennosc zapisów w blockchainie, która może pozostawać w sprzeczności z tzw. prawem do bycia zapomnianym. Rozwiązaniem może być zastosowanie koncepcji off-chain storage, w której dane użytkownika są przechowywane poza blockchainem, natomiast w samym łańcuchu zapisywane są jedynie ich skróty kryptograficzne (tzw. hash).

Podsumowując, bezpieczeństwo danych i ochrona prywatności w systemach blockchain dla użytkowników pojazdów elektrycznych są kwestiami kluczowymi, wymagającymi zaawansowanych rozwiązań technologicznych. Zastosowanie nowoczesnych mechanizmów anonimizacji, szyfrowania oraz zabezpieczeń przed cyberatakami umożliwi pełne wykorzystanie potencjału technologii blockchain, przy jednoczesnym zapewnieniu odpowiedniego poziomu ochrony informacji o użytkownikach. Wraz z dalszym rozwojem tej technologii można oczekiwać coraz lepszej integracji blockchaina z wymogami dotyczącymi prywatności oraz zgodności z regulacjami prawnymi.

6.4. Handel peer-to-peer w zarządzaniu energią w procesie ładowania pojazdu elektrycznego

Ważnym pojęciem pojawiającym się w dyskusji o zarządzaniu procesem ładowania pojazdów elektrycznych (EV) jest handel peer-to-peer (P2P) – innowacyjne rozwiązanie umożliwiające bezpośrednią wymianę energii między użytkownikami, bez konieczności korzystania z centralnych dostawców. Model ten pozwala na bardziej elastyczne i zdecentralizowane zarządzanie zasobami energetycznymi, szczególnie w kontekście rosnącego udziału odnawialnych źródeł energii (OZE). Dzięki technologii blockchain transakcje P2P mogą być realizowane w sposób bezpieczny, transparentny i automatyczny, co eliminuje potrzebę angażowania pośredników oraz redukuje koszty operacyjne (Gbadamosi i Nwulu 2024).

Jednym z kluczowych aspektów handlu P2P w sektorze elektromobilności jest możliwość tworzenia lokalnych mikrogridów energetycznych, umożliwiających wymianę energii w ramach społeczności użytkowników. Właściciele domowych instalacji fotowoltaicznych mogą sprzedawać nadwyżki energii bezpośrednio kierowcom pojazdów elektrycznych, co

sprzyja lokalnej autokonsumpcji oraz odciąża główne sieci elektroenergetyczne. Wprowadzenie inteligentnych kontraktów w technologii blockchain umożliwia automatyczne rozliczenia pomiędzy stronami i gwarantuje uczciwe i szybkie przetwarzanie transakcji.

Handel P2P może również wpłynąć na rozwój dynamicznych systemów cenowych, w których koszty energii zmieniają się w czasie rzeczywistym, w zależności od podaży i popytu. Taki model zachęca użytkowników do ładowania pojazdów w okresach nadwyżki energii, co sprzyja lepszemu bilansowaniu obciążenia sieci oraz zmniejsza ryzyko jej przeciążenia. Dodatkowo blockchain umożliwia przechowywanie szczegółowych informacji o pochodzeniu energii, co pozwala użytkownikom świadomie wybierać ekologiczne źródła zasilania i tym samym wspierać globalne dążenia do dekarbonizacji transportu.

Zastosowanie modelu P2P w infrastrukturze ładowania EV wiąże się jednak z wyzwaniami, takimi jak obowiązujące regulacje prawne dotyczące handlu energią, skalowalność rozwiązań blockchainowych oraz konieczność wdrożenia inteligentnych liczników i systemów zarządzania energią. Mimo tych barier rozwój technologii oraz rosnące zapotrzebowanie na elastyczne rozwiązania energetyczne sprawiają, że model peer-to-peer ma istotny potencjał, aby stać się integralną częścią przyszłego ekosystemu elektromobilności.

6.5. Nowe możliwości synergii

W miarę jak elektromobilność zyskuje na znaczeniu, coraz większą rolę odgrywa integracja różnych technologii w spójny, efektywny system zarządzania energią. Blockchain, jako narzędzie służące do bezpiecznego i transparentnego rejestrowania transakcji, staje się kluczowym ogniwem w budowie takiego systemu. Ponieważ łączy cyfrowe zarządzanie, odnawialne źródła energii (OZE), inteligentne sieci i zdecentralizowane modele współdzielenia zasobów, to zastosowanie go w infrastrukturze ładowania EV otwiera nowe perspektywy synergii (Gbadamosi i Nwulu 2024; Morawiec 2024).

Zintegrowanie blockchaina z infrastrukturą ładowania umożliwia nie tylko automatyzację rozliczeń i kontrolę dostępu do punktów ładowania, ale także dynamiczne sterowanie przepływem energii. Inteligentne kontrakty pozwalają na tworzenie elastycznych, warunkowych umów pomiędzy użytkownikami, operatorami i dostawcami energii. Dzięki temu możliwe staje się np. ładowanie pojazdu tylko energią pochodzącą z OZE, zakupioną bezpośrednio od lokalnego prosumenta.

Coraz większe znaczenie mają modele współpracy w ramach społeczności energetycznych, w których właściciele instalacji PV lub innych źródeł odnawialnych mogą dzielić się nadwyżkami energii z sąsiadami lub użytkownikami EV. Blockchain może zapewnić nie tylko rejestrowanie takich transakcji, ale także ich automatyczne rozliczanie, co eliminuje konieczność angażowania pośredników i ułatwia wdrażanie rozproszonych modeli biznesowych. Taka forma współdzielenia zasobów energetycznych stanowi przykład synergii technologii cyfrowych i energetyki obywatelskiej.

Istotnym aspektem tej synergii jest również bezpieczeństwo – zarówno w wymiarze danych, jak i transakcji. Dzięki zastosowaniu zaawansowanej kryptografii blockchain może chronić wrażliwe informacje i jednocześnie umożliwić ich weryfikację bez ujawniania

szczegółów. To rozwiązanie jest szczególnie istotne w kontekście wspomnianych wymogów RODO i rosnących zagrożeń cybernetycznych.

Technologia ta wspiera też integrację z inteligentnymi systemami zarządzania energią EMS (Energy Management System), umożliwiając m.in. dynamiczne ustalanie cen energii, sterowanie mocą ładowania oraz przewidywanie zapotrzebowania na energię w czasie rzeczywistym. W połączeniu z lokalnymi źródłami OZE i magazynami energii blockchain umożliwia tworzenie autonomicznych struktur energetycznych – elastycznych, skalowalnych i zorientowanych na użytkownika.

Podsumowując, synergiczne połączenie blockchaina, elektromobilności i odnawialnych źródeł energii otwiera nowe możliwości rozwoju inteligentnej infrastruktury ładowania. Tego typu zintegrowane podejście może przyczynić się do zwiększenia efektywności energetycznej, redukcji emisji CO₂ oraz budowy bardziej odpornych i sprawiedliwych modeli dystrybucji energii. Technologia blockchain, choć niepozbawiona wyzwań wdrożeniowych, może pełnić w tym procesie funkcję katalizatora, umożliwiając elastyczne, bezpieczne i transparentne współdziałanie wszystkich uczestników rynku energii.

7. Sztuczna inteligencja – czy prawo może uczynić AI bardziej ludzką?

7.1. Rys historyczny – perspektywa Unii Europejskiej

Od końca XX wieku jesteśmy świadkami rozwoju technicznego na niespotykaną wcześniej skalę. Dynamika zmian i gwałtowny przyrost informacji powodują, że społeczeństwo również się zmienia, starając się nadążyć za technologią. Truizmem jest stwierdzenie, że postęp techniczny ułatwia nasze życie. Dostrzegając jednak zalety współczesnych rozwiązań, należy mieć świadomość, że wymagają one, oprócz umiejętności tworzenia, również zrozumienia ich złożoności, wpływu na nasze życie oraz zagrożeń, jakie ze sobą niosą (Cichocki i Karbownik 2020, s. 46). To zaś prowadzi do wniosku, że konieczne jest stworzenie ram normatywnych, które z jednej strony regulują funkcjonowanie rynku nowoczesnych technologii, a z drugiej pełnią funkcję ochronną wobec ich użytkowników.

Technologie cyfrowe, w szczególności łączące dane, algorytmy i moc obliczeniową, od końca XX wieku rozwijają się w ogromnym tempie. Dzięki temu zauważalne są zwiększenie wydajności systemów produkcji, rolnictwa, poprawa opieki zdrowotnej czy zwiększenie bezpieczeństwa w wielu obszarach naszego życia. Równocześnie obawy wzbudza brak przewidywalności, nieprzejrzyste podejmowanie decyzji, zbieranie danych w niekontrolowany sposób i ingerencja w życie prywatne (Burczaniuk 2024). Potencjalne zagrożenie dla praw podstawowych spowodowało podjęcie działań w Unii Europejskiej, których celem jest z jednej strony zapewnienie bezpieczeństwa stosowania technologii cyfrowych, a z drugiej wsparcie ich rozwoju. W niniejszym rozdziale przedstawione zostaną podstawowe założenia prawa sztucznej inteligencji z perspektywy unijnej.

W kwietniu 2018 r. przedstawiony został przez Komisję Europejską komunikat w sprawie sztucznej inteligencji (Komisja Europejska 2018). Następnie Komisja opublikowała w lutym 2020 r. białą księgę (Komisja Europejska 2020) w sprawie sztucznej inteligencji, której celem było określenie strategicznych sposobów osiągnięcia dwóch założeń: promowania sztucznej inteligencji i zapobiegania zagrożeniom związanym z niektórymi jej zastosowaniami. Biała księga nie odnosi się do rozwoju i wykorzystania sztucznej inteligencji w celach wojskowych. Kolejne kroki należały do Parlamentu Europejskiego, który w tym samym roku, a także w późniejszym okresie wydał szereg rezolucji dotyczących sztucznej inteligencji. Wśród nich wymienić należy rezolucję Parlamentu Europejskiego z dnia 20 października 2020 r. z zaleceniami dla Komisji w sprawie systemu odpowiedzialności cywilnej za sztuczną inteligencję,

rezolucję Parlamentu Europejskiego z dnia 20 października 2020 r. zawierającą zalecenia dla Komisji w sprawie ram aspektów etycznych sztucznej inteligencji, robotyki i powiązanych z nimi technologii, rezolucję Parlamentu Europejskiego z dnia 20 października 2020 r. w sprawie praw własności intelektualnej w dziedzinie rozwoju technologii sztucznej inteligencji, jak również rezolucję Parlamentu Europejskiego z dnia 3 maja 2022 r. w sprawie sztucznej inteligencji w epoce cyfrowej.

Wspomnieć również można rozporządzenie Parlamentu Europejskiego i Rady (UE) 2021/694 z dnia 29 kwietnia 2021 r. ustanawiające program „Cyfrowa Europa” oraz Decyzję Parlamentu Europejskiego i Rady (UE) 2022/2481 z dnia 14 grudnia 2022 r. ustanawiającą program polityki „Droga ku cyfrowej dekadzie” do 2030 r.

Efektom prac instytucji unijnych był opublikowany przez Komisję Europejską w dniu 21 kwietnia 2021 r. projekt rozporządzenia w sprawie sztucznej inteligencji (dalej: akt w sprawie AI). Była to pierwsza na świecie inicjatywa legislacyjna, której celem było utworzenie ram prawnych dla funkcjonowania tej technologii. Projekt ten wzbudził ogromne zainteresowanie przede wszystkim przedstawicieli twórców systemów AI.

Tego samego dnia opublikowany został wniosek dotyczący nowego rozporządzenia w sprawie maszyn, wraz z jedenastoma załącznikami, odnoszący się do ważnego aspektu sztucznej inteligencji – zwykle określanego jako „robotyka”, a niedługo potem pojawił się wniosek dotyczący nowego rozporządzenia w sprawie ogólnego bezpieczeństwa produktów.

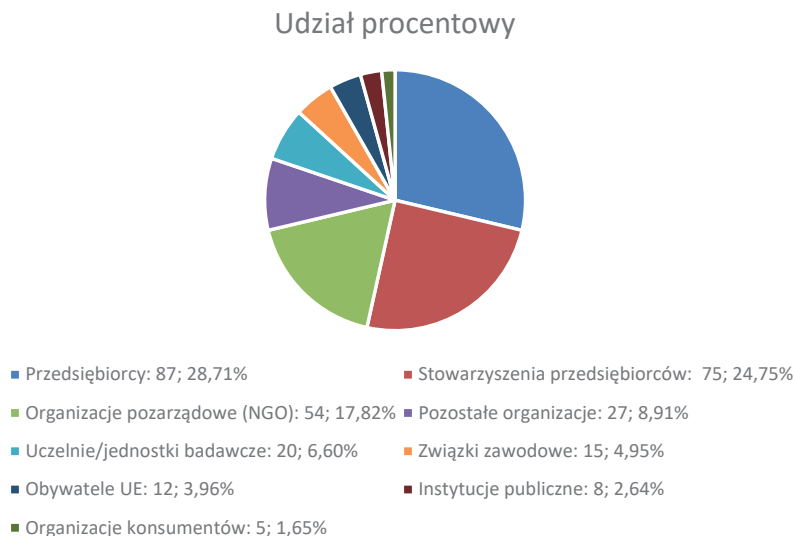
Wybór rozporządzenia jako aktu prawnego jest w pełni uzasadnione w przypadku technologii, która działa najczęściej ponad granicami. Rozporządzenie ma zasięg ogólny. Wiąże w całości i jest bezpośrednio stosowane we wszystkich państwach członkowskich. Natomiast w przeciwieństwie do niego dyrektywa wiąże każde państwo członkowskie, do którego jest kierowana, w odniesieniu do rezultatu, który ma być osiągnięty, pozostawia jednak organom krajowym swobodę wyboru formy i środków (art. 288 Traktatu o funkcjonowaniu Unii Europejskiej). Dyrektywy wymagają transponowania, włączenia ich do prawa krajowego i proces ten bywa wadliwy. W przypadku aktu prawnego o bezpośrednim stosowaniu unika się odmiennej treści przepisów w różnych państwach członkowskich.

7.2. Konsultacje społeczne

W wyniku konsultacji społecznych, które zostały zakończone 6 sierpnia 2021 r., Komisja otrzymała 304 stanowiska dotyczące projektu aktu w sprawie sztucznej inteligencji. W konsultacjach swoje poglądy przedstawili przedsiębiorcy, stowarzyszenia przedsiębiorców, organizacje pozarządowe (NGO), uczelnie i jednostki badawcze, związki zawodowe, organy administracji publicznej, organizacje konsumentów oraz inne organizacje i obywatele unijni. Rysunek 7.1 przedstawia wielkość udziału poszczególnych przedstawicieli społeczeństwa, którzy zdecydowali się na udział w konsultacjach społecznych dotyczących aktu w sprawie sztucznej inteligencji, z podziałem na branże.

Projekt wywołał sprzeciw przede wszystkim ze strony przedsiębiorców z branży nowoczesnych technologii. Wśród zarzutów, które z jednej strony były do przewidzenia, a z drugiej trudno je bezkrytycznie akceptować, była krytyka wymogu, aby dane treningowe były wolne

od błędów. Zarzuty tłumaczono brakiem możliwości spełnienia takiego wymogu. Kwestionowano konieczność uwzględnienia możliwości i zachowań człowieka, tak aby użytkownik w pełni rozumiał możliwości i ograniczenia systemu AI, argumentując, że twórca systemu nie może przewidzieć, co zrozumie użytkownik (tak np. IBM Submission to the European Commission on the Draft Artificial Intelligence Act, 2021).



Rys. 7.1. Udział poszczególnych przedstawicieli społeczeństwa w konsultacjach społecznych na temat projektu aktu w sprawie sztucznej inteligencji

Uwagi lobby związanego z tworzeniem systemów AI w znacznym stopniu wpłynęły na ostateczną treść aktu w sprawie sztucznej inteligencji, który znacznie odbiega od początkowej wersji zawierającej szereg założeń chroniących użytkownika systemu. Ostatecznie – dane mają być adekwatne, wystarczająco reprezentatywne oraz w jak największym stopniu wolne od błędów i kompletne pod względem przeznaczenia. Krytykowano prawo dostępu organu nadzoru do kodu źródłowego, argumentując to tym, że stanowi to zagrożenie dla tajemnicy przedsiębiorstwa i innych praw własności intelektualnej oraz że kod źródłowy nie jest niezbędny do kontroli budowy systemu AI. Uwagi przedsiębiorców zostały w przeważającej mierze uwzględnione i w rezultacie przyjęto wersję aktu, która znacznie odbiega od początkowego projektu.

W związku z udostępnieniem w listopadzie 2022 r. chaty GPT projekt jeszcze przed jego opublikowaniem stał się niewyczerpujący i niedostosowany do istniejących i szeroko wykorzystywanych technologii. To spowodowało konieczność wprowadzenia zmian i uzupełnienia projektu rozporządzenia o normy dotyczące modeli AI ogólnego przeznaczenia. Akt w sprawie sztucznej inteligencji w konsekwencji odbiega od jego początkowego projektu z 2021 r. i spotkać można się z opinią, że stanowi polityczny kompromis między Unią a twórcami systemów sztucznej inteligencji.

7.3. Konkretyzacja środków prawnych

Chronologicznie akt w sprawie sztucznej inteligencji poprzedzony był rozporządzeniem Parlamentu Europejskiego i Rady (UE) 2021/694 z dnia 29 kwietnia 2021 r. ustanawiającym program „Cyfrowa Europa” oraz uchylającym decyzję (UE) 2015/2240 oraz decyzją Parlamentu Europejskiego i Rady (UE) 2022/2481 z dnia 14 grudnia 2022 r. ustanawiającą program polityki „Droga ku cyfrowej dekadzie” do 2030 r.

Akt w sprawie sztucznej inteligencji wszedł w życie 1 sierpnia 2024 r. (Rozporządzenie Parlamentu Europejskiego i Rady (UE) 2021/694 z dnia 29 kwietnia 2021 r. ustanawiające program „Cyfrowa Europa” oraz uchylające decyzję (UE) 2015/2240 (Dz.Urz.UE.L 2024.166)). Jego głównym celem było wprowadzenie norm zapewniających bezpieczeństwo przy korzystaniu z systemów sztucznej inteligencji, które w świadomości społecznej będą wiarygodnym narzędziem. Równocześnie intencją aktu jest stymulowanie rozwoju sztucznej inteligencji. Pod względem założenia stwierdzającego, że systemy godne zaufania i wiarygodne dla ludzi przyczyniają się do wzrostu popytu, a tym samym do wzrostu podaży i w konsekwencji zachęcają do inwestycji w obszarze AI, oba cele aktu są spełnione.

Zaznaczyć należy, że publikacji aktu w sprawie AI towarzyszy powstanie konwencji ramowej Rady Europy o sztucznej inteligencji i prawach człowieka, demokracji i praworządności. Konwencja wejdzie w życie po ratyfikowaniu jej przez co najmniej trzy państwa członkowskie Rady Europy; została ona otwarta do podpisu w dniu 5 września 2024 r. i wtedy została podpisana przez pierwsze państwa i przez Unię Europejską. Warto zwrócić uwagę, że podmiotowy i przedmiotowy zakres zastosowania konwencji oraz jej przepisy materialne pokrywają się w dużym stopniu z aktem w sprawie sztucznej inteligencji oraz innymi przepisami unijnymi, co sprawia, że zawarcie konwencji ma wpływ na zakres ich stosowania. Z tego względu konwencja Rady Europy została podpisana przez Komisję Europejską po upoważnieniu przez Radę Unii Europejskiej (Decyzja Rady (UE) 2024/2218 z dnia 28 sierpnia 2024 r. w sprawie podpisania, w imieniu Unii Europejskiej, Konwencji ramowej Rady Europy w sprawie sztucznej inteligencji, praw człowieka, demokracji i praworządności). Akt w sprawie sztucznej inteligencji jest pierwszym kompleksowym rozporządzeniem w tej sprawie na świecie, a Konwencja Rady Europy jest pierwszym międzynarodowym instrumentem dotyczącym tego zagadnienia. W porównaniu z aktem unijnym konwencja Rady Europy może mieć znacznie szerszy zasięg terytorialny, ponieważ jest otwarta do podpisu nie tylko przez państwa członkowskie Rady Europy i Unię Europejską, ale również przez państwa nieczłonkowskie, które brały udział w jej powstaniu oraz przez państwa nieczłonkowskie z całego świata, które chcą do niej przystąpić. W negocjacjach, oprócz Unii Europejskiej, brały udział inne państwa członkowskie Rady Europy, USA, Kanada, Meksyk, Japonia, Izrael, Australia, Argentyna, Peru, Urugwaj i Kostaryka.

Konwencja jest spójna z aktem w sprawie sztucznej inteligencji i nie pozostaje w kolizji z innymi przepisami unijnymi, na co niewątpliwie istotny wpływ miało zaangażowanie Komisji Europejskiej i państw członkowskich Unii. Konwencja, tak jak to ujęto w komunikacie Komisji Europejskiej (2024), „obejmuje szereg kluczowych pojęć zawartych w akcie w sprawie sztucznej inteligencji, takich jak:

- skoncentrowanie się na sztucznej inteligencji ukierunkowanej na człowieka, zgodnej z prawami człowieka, demokracją i praworządnością;

- podejście oparte na analizie ryzyka;
- kluczowe zasady godnej zaufania sztucznej inteligencji (np. przejrzystość, solidność, bezpieczeństwo, zarządzanie danymi i ich ochrona);
- przejrzystość treści generowanych przez sztuczną inteligencję i interakcji z systemami sztucznej inteligencji;
- wzmocniona dokumentacja, rozliczalność i środki zaradcze;
- wspieranie bezpiecznych innowacji za pośrednictwem piaskownic regulacyjnych;
- obowiązki w zakresie zarządzania ryzykiem;
- obowiązki w zakresie dokumentacji;
- mechanizmy nadzoru nad działalnością związaną ze sztuczną inteligencją”.

Rozporządzenie powinno zapewnić swobodny transgraniczny przepływ towarów i usług opartych na AI, uniemożliwiając tym samym państwom członkowskim nakładanie ograniczeń na rozwój, wprowadzanie do obrotu i wykorzystywanie systemów AI, chyba że jest to wyraźnie dozwolone w rozporządzeniu (Michałowicz 2021). W motywie 1 preambuły aktu w sprawie sztucznej inteligencji czytamy: „celem rozporządzenia 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 inteligencji w Unii, zgodnie z wartościami Unii, w celu promowania, upowszechniania zorientowanej na człowieka i godnej zaufania sztucznej inteligencji, przy jednoczesnym zapewnieniu wysokiego poziomu ochrony zdrowia, bezpieczeństwa, praw podstawowych zapisanych w Karcie praw podstawowych Unii Europejskiej, w tym demokracji, praworządności i ochrony środowiska, ochrony przed szkodliwymi skutkami systemów AI w Unii, a także wspierania innowacji”.

W świetle powyższych deklaracji cele aktu są zatem idealne i trudne do podważenia. Niemniej analiza jego treści prowadzi do wniosku, że jest to instrument dalece niewystarczający do osiągnięcia deklarowanych celów (zresztą – nigdy nie obiecywano, że nim będzie). Większość przepisów odnoszących się do obowiązków w zakresie systemów AI wymaga dochowania należytej staranności, a nie doprowadzenia do pewnego rezultatu. Jako przykład wskazać można artykuł 4 aktu w sprawie sztucznej inteligencji, który wymaga, aby dostawcy i podmioty stosujące systemy AI „podejmowali środki w celu zapewnienia w możliwie największym stopniu” odpowiedniego poziomu kompetencji w zakresie AI wśród personelu. Podobnie, zbiory danych treningowych, walidacyjnych i testowych muszą być „adekwatne, wystarczająco reprezentatywne oraz w jak największym stopniu wolne od błędów” (art. 10 ust. 3 aktu), co wyraźnie wskazuje na to, że mogą one błędy zawierać. Przy takim przyzwoleniu względnie akceptacji realiów treningowych systemów AI brakuje w akcie obowiązku wyraźnego informowania o tym użytkownika systemu, który w praktyce o tym często nie wie, pokładając w systemie nadmierne zaufanie. To samo dotyczy obowiązków podmiotu stosującego systemy AI wysokiego ryzyka, który ma zapewnić, aby dane wejściowe, nad którymi sprawuje kontrolę, były „adekwatne i wystarczająco reprezentatywne” (art. 26 ust. 4 aktu). Argumentami przemawiającymi za istnieniem raczej obowiązku starannego działania, a nie osiągnięcia określonego rezultatu, przemawiać może np. to, że jego osiągnięcie nie jest możliwe – np. w zakresie prawdziwości danych wejściowych. Niemniej, jeżeli takie wyjaśnienie jest

trafne, to żaden z systemów AI nie może dać pewnych rezultatów. W konsekwencji, z punktu widzenia ochrony użytkowników systemu, aby zapewnić im deklarowane w rozporządzeniu bezpieczeństwo i możliwość działania w zaufaniu do sztucznej inteligencji, konieczne jest stałe i konsekwentne zwracanie uwagi użytkownika, iż – paradoksalnie – nie powinien systemowi ufać. A takiego obowiązku, jak się łatwo domyślić, w żadnym akcie normatywnym ani projektach przyszłych aktów nie ma.

W praktyce treść aktu w sprawie AI zdeterminuje Komisja Europejska i w przyszłości orzecznictwo. Zgodnie z artykułem 96 aktu w sprawie AI Komisja opracowuje wytyczne w sprawie wdrożenia rozporządzenia. Kompetencje Komisji dotyczące zakresu wytycznych w zasadzie są nieograniczone. Komisja powinna jedynie zwrócić szczególną uwagę na potrzeby małych i średnich przedsiębiorstw, w tym przedsiębiorstw typu start-up, lokalnych organów publicznych i sektorów, na które rozporządzenie może mieć największy wpływ, przy czym sektory te również określa Komisja, uwzględniając powszechnie uznany stan wiedzy technicznej w dziedzinie AI. Jedynie przykładowo wymienione są obszary, które powinny być uwzględnione w wytycznych. Wśród nich znajduje się określenie zasad postępowania w zakresie obowiązków dotyczących z systemów AI wysokiego ryzyka związanych np. z systemem zarządzania ryzykiem, zarządzaniem danymi, dokumentacją techniczną, rejestrowaniem zdarzeń, przejrzystością i udostępnianiem informacji podmiotom stosującym, nadzorem ze strony człowieka i cyberbezpieczeństwem oraz odpowiedzialnością w całym łańcuchu wartości AI. Wytyczne powinny również wyjaśnić wątpliwości rodzące się w związku z przepisami dotyczącymi zakazanych praktyk AI. To samo dotyczy obowiązków w zakresie przejrzystości dla dostawców systemów wchodzących w bezpośrednią interakcję z osobami fizycznymi oraz podmiotów stosujących systemy AI generujące treści w postaci syntetycznych dźwięków, obrazów, wideo lub tekstu (w tym systemy ogólnego zastosowania), systemy rozpoznawania emocji lub systemy kategoryzacji biometrycznej, systemy, które generują obrazy lub treści stanowiące deep fake, jak również podmiotów stosujących system AI, który generuje tekst publikowany w celu informowania społeczeństwa o sprawach leżących w interesie publicznym. Dodatkowo wytyczne mają dotyczyć wdrożenia rozporządzenia w obszarze rzeczywistego wprowadzania w życie obowiązków w zakresie przejrzystości oraz podawania szczegółowych informacji na temat powiązań między aktem w sprawie sztucznej inteligencji a unijnym prawodawstwem, w tym w odniesieniu do spójności jego egzekwowania.

Warto zwrócić uwagę, że upoważnienie Komisji do zmiany ustalonych wytycznych z własnej inicjatywy lub inicjatywy urzędu do spraw AI względnie na wniosek państw członkowskich oraz dokonania ich aktualizacji, zapewnia z jednej strony możliwość stosunkowo prostego ich dostosowywania do zmieniającej się sytuacji i postępu technicznego, a z drugiej jest jednym z wielu przykładów znaczenia i pozycji Komisji Europejskiej.

Z pewnością kluczowe znaczenie będą miały wytyczne odnoszące się do samej definicji systemu AI znajdującej się w akcie w sprawie AI, w świetle której „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 (art. 3 pkt 1 aktu w sprawie AI).

Podsumowując, należy stwierdzić, że podstawowe założenia aktu w sprawie sztucznej inteligencji obejmują zarządzanie i doprowadzenie do transparentności budowy i działania systemu sztucznej inteligencji, ze wskazaniem, że funkcjonowanie systemu AI i modelu AI ogólnego przeznaczenia podlega nadzorowi człowieka. Wobec aktu można wysunąć zastrzeżenia, że zarówno jego systematyka, jak i treść wykazują duży stopień ogólności, a metoda regulacji tworzenia i wprowadzania systemów AI i modułów AI ogólnego zastosowania ma charakter administracyjnoprawny, a w konsekwencji stawia rzeczywistych zainteresowanych, czyli osoby korzystające z systemów AI, na marginesie ich tworzenia i stosowania. Niemniej jest to pierwszy krok w kierunku uregulowania odpowiedzialności cywilnoprawnej za działania AI. Metoda administracyjnoprawna, która obejmuje relacje między wskazanymi w akcie podmiotami (dostawcami, importerami, dystrybutorami i podmiotami stosującymi niektóre systemy AI) oraz organem nadzoru, jako taka nie może co do zasady obejmować roszczeń prywatnoprawnych, a tym bardziej – takie spory nie powinny być „niechcący” wyłączane z zakresu kompetencji sądów ewentualnym „przesunięciem” na drogę administracyjnoprawną. Dochodzenie roszczeń na drodze sądowej i dominacja prawa prywatnego w regulowaniu stosunków między różnymi uczestnikami obrotu jest nieodłączną cechą demokracji i zasady swobody działalności gospodarczej i wszystkich swobód będących podstawą funkcjonowania Unii. Niemniej użytkownik systemu bez wsparcia systemowego nie ma realnych szans na skuteczne dochodzenie roszczeń. Z tego powodu przepisy określające wymagania dotyczące danych i zarządzania danymi, dokumentacji technicznej, rejestrowania zdarzeń, przejrzystości i udostępniania informacji podmiotom stosującym, nadzoru ze strony człowieka oraz dokładności, solidności i cyberbezpieczeństwa są istotne i mogą ułatwić np. wykazanie związku przyczynowego między ewentualną szkodą a niedopełnieniem obowiązku przez dostawcę, importera lub dystrybutora. Ewentualne działania Komisji i przeprowadzone przez nią postępowanie może także przyczynić się do ułatwienia dochodzenia roszczeń odszkodowawczych; w świetle aktu w sprawie sztucznej inteligencji jej kompetencje w zakresie m.in. postępowania dowodowego, w tym zbierania dowodów, są bardzo duże i jeżeli jego rezultaty mogłyby być wykorzystane w postępowaniu sądowym, doszłoby do faktycznego zniwelowania systemowego braku równości między dostawcą a użytkownikiem systemu AI. Nie uchybia to twierdzeniu, że konieczne jest uregulowanie odpowiedzialności za szkodę powstałą w związku z systemem AI, zarówno w obszarze materialnoprawnym, jak i procesowym. Warto byłoby zastanowić się nad kwestią funkcji i roli postępowania prowadzonego na podstawie aktu w sprawie sztucznej inteligencji w postępowaniu cywilnym, w tym – jakie znaczenie procesowe może mieć jego brak. Konieczna jest akceptacja zasady odwróconego ciężaru dowodu w postępowaniu lub domniemań prawnych w obszarze zarówno prawa materialnego, jak i procesowego. Wydaje się również, że w sytuacji przywiązania państw europejskich do własnych koncepcji prawnych i tradycji procesowych lepszy rezultat (w postaci większej skuteczności) przyniosłoby posłużenie się formą rozporządzenia jako aktu normatywnego regulującemu ten obszar.

Snując rozważania na temat sztucznej inteligencji, musimy mieć świadomość, że pomimo powszechnego używania, zarówno w literaturze, jak i w aktach prawnych lub ich projektach,

terminów: sztuczna inteligencja, system, model sztucznej inteligencji, każdy z tych terminów obejmuje program komputerowy, tyle że wykazujący specyficzne cechy, zapewniające znaczną autonomię jego działania. Lapidarnie mówiąc, nie ma sztucznej inteligencji bez programu komputerowego, obojętne, czy funkcjonującego niezależnie od konkretnej maszyny, czy też integralnie z nią związanego (Lai i Świerszczyński 2020; Michalak 2021).

W doktrynie spotkać można wprawdzie postulat przyznania sztucznej inteligencji „osobowości elektronicznej” (Anusz 2025), jednak jest to stanowisko odosobnione (Wendehorst 2022). Personifikacja „sztucznej inteligencji” – czyli de facto systemu programów komputerowych – wbrew pozorom nie zbliży jej do człowieka, gdyż ani jej do człowieka nie upodobni, ani nie zwiększy zaufania do niej. Nie byłby to dobry kierunek i obecnie myśl ta – po szerokiej krytyce rezolucji Parlamentu Europejskiego (Rezolucja Parlamentu Europejskiego z dnia 16 lutego 2017 r. zawierająca zalecenia dla Komisji w sprawie przepisów prawa cywilnego dotyczących robotyki (2018/C 252/25)) – nie jest dalej rozwijana. W szczególności, wydaje się wątpliwe, aby stworzenie dodatkowego bytu prawnego, mogłoby pozytywnie wpływać na wykorzystanie sztucznej inteligencji dzięki zaufaniu, które w niej by pokładano. Czynnikiem budującym zaufanie do AI są przewidywalność rezultatu pracy z nią, co z kolei wynika z transparentności jej budowy i zasad działania, oraz przekonanie, że w przypadku, gdyby doszło do wyrządzenia szkody w związku z korzystaniem z systemu AI, zostanie ona naprawiona, czego podstawowym warunkiem jest ustalenie podmiotu odpowiedzialnego za szkodę. Konstruowanie „osobowości elektronicznej” nie da się pogodzić z zasadą odpowiedzialności za szkodę. Można sobie wprawdzie wyobrazić, że jest ona konstruowana na wzór osoby prawnej, np. fundacji, jednak w obecnym stanie prawnym taka koncepcja nie jest zrealizowana (można powiedzieć, że na szczęście) i nie wydaje się potrzebna (Chłopecki 2021).

Zagadnienia związane z bytem sztucznej inteligencji prowadzą nas zatem w obecnym stanie prawnym i technicznym do rozważań dotyczących ochrony prawnej programów komputerowych oraz do odpowiedzialności za działania programu komputerowego – która obecnie nie została odrębnie uregulowana (Krasuski 2021). Obserwując rozwój systemu prawa, można odnieść wrażenie, że nie zdążył objąć swym zakresem tego specyficznego zagadnienia i zajął się od razu inicjatywą legislacyjną w odniesieniu do jego kolejnego etapu rozwoju, tj. odpowiedzialności za system sztucznej inteligencji.

Obok aktu w sprawie sztucznej inteligencji, kolejnym aktem normatywnym, który kreuje nową rzeczywistość prawną jest Dyrektywa Parlamentu Europejskiego i Rady (UE) 2024/2853 z dnia 23 października 2024 r. w sprawie odpowiedzialności za produkty wadliwe i uchylecia dyrektywy Rady 85/374/EWG. W zasadniczy sposób zmienia ona definicję produktu, dostosowując ją do współczesnych realiów rozwoju technicznego i rynku. Omówienie jej chociażby w skromnym zakresie wykracza poza ramy niniejszego rozdziału, niemniej jej praktyczne znaczenie wydaje się nie do przecenienia. Zdefiniowanie produktu jako „rzecz ruchomą, nawet jeżeli jest ona zintegrowana lub wzajemnie połączona z inną rzeczą ruchomą lub nieruchomą; obejmuje to energię elektryczną, cyfrowe pliki produkcyjne, surowce i oprogramowanie” koresponduje z założeniami aktu w sprawie sztucznej inteligencji i jest pierwszym aktem normatywnym regulującym zasady odpowiedzialności za działania programu komputerowego i pośrednio także AI.

7.4. Ocena europejskiej koncepcji legislacyjnej

Podobnie jak wiele innych słów słowo „ludzki” ma wiele znaczeń (Ciunovič 2023). Zgodnie z definicją podaną przez słowniki języka polskiego, ludzki to m.in. „taki, który zaspokaja potrzeby człowieka w stopniu odpowiednim”, np. ludzkie warunki pracy, ludzkie warunki mieszkania; w innym znaczeniu: „związany z człowiekiem – kimś przyzwoitym”, np. ludzki szef, ludzki gest lub „związany z człowiekiem – istotą rozumną”, np. ludzki głos, ludzkie osiedle. Norma prawna rozumiana jako reguła postępowania określona przez prawo nie ma mocy magicznych i nie sprawi, że jakiegokolwiek narzędzie zacznie odczuwać emocje i wykazywać się empatią i wrażliwością społeczną. W tym zakresie prawo jest bezsilne. Celem inicjatyw legislacyjnych w Unii Europejskiej jest bowiem zapewnienie, aby sztuczna inteligencja (w tym: systemy sztucznej inteligencji, modele sztucznej inteligencji ogólnego przeznaczenia) była wiarygodnym instrumentem, z którego można korzystać z przekonaniem, że nie doprowadzi to do przekroczenia granic norm społecznych i prawnych, przy równoczesnym realizowaniu potrzeb użytkownika.

Treść proponowanych norm, pomimo wad, które zawsze towarzyszą (ludzkiemu i sztucznej inteligencji) działaniu, jest spójna z założonymi celami. Pomimo zatem ograniczonych jego naturą możliwości prawa możemy wykazać optymizm i stwierdzić, że jego rozsądna treść w połączeniu z rzetelnym stosowaniem może sprawić, że sztuczna inteligencja stanie się bardziej ludzka i dostępna dla człowieka, zarówno pod względem poznawczym, jak i użytkowym.

Zakończenie

Wnioski wynikające z analiz zawartych w niniejszej monografii jednoznacznie wskazują, że rozwój sztucznej inteligencji stanowi nie tylko czynnik wspierający efektywność informatycznych systemów zarządzania, lecz także zmienia ich charakter i funkcję. AI przestaje być dodatkiem do systemów ISZ – staje się ich integralną częścią, redefiniując sposób przetwarzania informacji, podejmowania decyzji oraz organizacji pracy w przedsiębiorstwach.

Przeprowadzone badania wykazały, że informatyczne systemy zarządzania są coraz szerzej wykorzystywane przez polskie MŚP. Najczęściej wdrażane systemy to ERP i CRM, a głównymi barierami implementacyjnymi pozostają koszty i brak kompetencji technologicznych. Potwierdzono jednocześnie pozytywny wpływ ISZ na efektywność operacyjną i jakość decyzji zarządczych.

Okazuje się, że w branży windykacyjnej integracja ISZ z AI przyczynia się do poprawy skuteczności działań windykacyjnych oraz do lepszego dopasowania strategii kontaktu z dłużnikami. Wykorzystanie AI do predykcji zachowań dłużników i automatyzacji działań przynosi realne korzyści ekonomiczne.

Na podstawie badań można podkreślić, że zastosowanie AI do zarządzania dokumentacją procesową zwiększa szybkość obiegu informacji i minimalizuje ryzyko błędów ludzkich. Zaprezentowany prototyp systemu może stać się punktem wyjścia dla wdrożeń w innych firmach obsługujących duże wolumeny dokumentów prawnych.

W monografii udowodniono również, że odpowiednie metody przetwarzania zbiorów niebalansowanych – powszechnych w danych operacyjnych – mogą znacząco zwiększyć skuteczność algorytmów klasyfikacyjnych i predykcyjnych, co ma zastosowanie w wielu sektorach, zwłaszcza w analizie ryzyka.

Zrealizowane badania wskazały na możliwość zastosowania AI do optymalizacji komunikacji interpersonalnej wewnątrz organizacji. Włączenie narzędzi psychometrycznych i testów osobowościowych do cyfrowego zarządzania zespołem może przełożyć się na lepsze wyniki w pracy zespołowej i zarządzaniu talentami.

Wykazano ponadto, że integracja technologii blockchain i AI może zrewolucjonizować sektor elektromobilności, szczególnie w kontekście zarządzania infrastrukturą ładowania i transakcjami energetycznymi peer-to-peer. Technologia ta otwiera nowe możliwości w zakresie bezpieczeństwa danych i transparentności procesów.

W monografii zwrócono uwagę na pilną potrzebę wprowadzenia przepisów prawnych i norm etycznych regulujących rozwój i wdrażanie AI. Autorzy postulują stworzenie

zrównoważonych ram prawnych, które z jednej strony umożliwią rozwój innowacji, a z drugiej zagwarantują bezpieczeństwo użytkowników oraz przejrzystość działań systemów autonomicznych.

Reasumując, wszystkie badania przedstawione w monografii wskazują na konieczność przemyślanej i odpowiedzialnej integracji sztucznej inteligencji z informatycznymi systemami zarządzania. Kluczowe stają się: inwestycje w kompetencje cyfrowe, otwartość na innowacje, zapewnienie interoperacyjności systemów oraz wzmocnienie ram regulacyjnych i etycznych. Przyszłość informatycznych systemów zarządzania bez AI wydaje się coraz mniej prawdopodobna, a z AI – coraz bardziej wymagająca odpowiedzialności, wiedzy i wizji.

Na zakończenie monografii autorzy wysuwają postulat kontynuowania badań nad praktycznym wdrażaniem AI w różnych branżach, rozwijaniem standardów jakościowych oraz upowszechnianiem dobrych praktyk w zakresie projektowania, testowania i nadzoru nad inteligentnymi systemami zarządzania.

Bibliografia

- Agustianto K., Destarianto P., 2019. *Imbalance data handling using neighbourhood cleaning rule (NCL) sampling method for precision student modeling*, [w:] 2019 International Conference on Computer Science, Information Technology, and Electrical Engineering (ICOMITEE), Jember, Indonesia, 86–89, <https://doi.org/10.1109/ICOMITEE.2019.8921159>.
- Alejo R., Sotoca J.M., Valdovinos R.M., Toribio P., 2010. *Edited Nearest Neighbor Rule for Improving Neural Networks Classifications*, [w:] L. Zhang, B.L. Lu, J. Kwok (Eds.), *Advances in Neural Networks – ISNN 2010. 7th International Symposium on Neural Networks, ISNN 2010, Shanghai, China, June 6–9, 2010, Proceedings, Part I* „Lecture Notes in Computer Science”, 6063, https://doi.org/10.1007/978-3-642-13278-0_39.
- Alphamoon.ai, 2023. *Debt collection, process automation*, <https://alphamoon.ai/blog/document-processing-in-automated-debt-collection/#:~:text=OCR%20%26%20Data%20Extraction> [11.03.2025].
- Alphamoon.ai, 2024. *Case study: skip tracing in KRUK*, <https://alphamoon.ai/blog/case-study-skip-tracing-in-kruk/> [11.03.2025].
- Anusz A., 2025. *Publiczne prawo ochrony konkurencji a nowe techniki i technologie na przykładzie wykorzystania danych lub ich baz, świadczenia usług cyfrowych lub zastosowania sztucznej inteligencji*. C.H. Beck, Warszawa.
- Ashton M.C., Lee K., 2007. *Empirical, theoretical, and practical advantages of the HEXACO model of personality structure*. „Personality and Social Psychology Review”, 11(2), 150–166, <https://doi.org/10.1177/1088868306294907>.
- A’yun A.H.Q., Prihartono B., 2025. *Business process management (BPM) maturity in small and medium enterprises (SMEs): Systematic Literature Review*. „Performa: Media Ilmiah Teknik Industri”, 24(1), 92–102, <https://doi.org/10.20961/performa.24.1.91112>.
- Barcik R., Jakubiec M., 2011. *Systemy logistyczne – podstawy funkcjonowania*. „Logistyka”, 4, 74–79.
- Barley S., Meyerson D.E., Grodal S., 2011. *E-mail as a source and symbol of stress*. „Organization Science”, 22(4), 887–906, <https://doi.org/10.2307/20868902>.
- Barszczewska K., 2016. *Opodatkowanie umowy przelewu wierzytelności podatkiem od czynności cywilnoprawnych*. „Zeszyty Naukowe UMCS”, 19(31), 21–26, <https://doi.org/10.17951/szn.2016.19.31.21>.
- Bartlett L., Kabir A., Han J., 2023. *A review on business process management system design: The role of virtualization and work design*. „IEEE Access”, 11, 116786–116819, <https://doi.org/10.1109/ACCESS.2023.3323445>.

- Bharath S.T., Shumway T., 2008. *Forecasting default with the Merton distance to default model*. „The Review of Financial Studies”, 21(3), 1339–1369, <https://doi.org/10.1093/rfs/hhn044>.
- Bodys S., 2019. *Uwarunkowania i efekty wdrożenia systemów ERP w małych i średnich przedsiębiorstwach* [rozprawa doktorska]. Uniwersytet Marii Curie-Skłodowskiej, Lublin, <https://bc.umcs.pl/Content/44668/Rozprawa%20doktorska%20-%20Sylwester%20Bodys.pdf> [3.02.2025].
- Boguszewski R., Gop A., Koc M., Piłat A., Walewski M., 2024. *Cyfryzacja w sektorze MŚP – szanse i ograniczenia*, https://www.bgk.pl/files/public/Raporty/Raport_cyfryzacja_BGK.pdf [22.01.2025].
- Bradford M., 2020. *Modern ERP: Select, Implement, and Use Today's Advanced Business Systems*. Fourth Edition. Marianne Bradford.
- Burczaniuk P., 2024. *Tworzenie prawa sztucznej inteligencji – wyzwania i perspektywy*. „Prawo i Więź”, 4(51), 283–300, <https://doi.org/10.36128/PRIW.VI51.707>.
- BusinessWire, 2022. *Global Soft Skills Training Market Report 2022: Market to Reach \$47 Billion by 2027*, <https://www.businesswire.com/news/home/20220221005400/en/Global-Soft-Skills-Training-Market-2022-to-2027---Industry-Trends-Share-Size-Growth-Opportunity-and-Forecasts---ResearchAndMarkets.com> [9.03.2025].
- Cattell R.B., Eber H.W., 1964. *Sixteen personality factor questionnaire*. Institute for Personality and Ability Testing, Washington.
- Ceci L., 2024. *Daily number of e-mails worldwide 2018–2027*, <https://www.statista.com/statistics/456500/daily-number-of-e-mails-worldwide/><https://www.statista.com/statistics/456500/daily-number-of-e-mails-worldwide/> [9.03.2025].
- Chłopecki A., 2021. *Sztuczna inteligencja – szkice prawnicze i futurologiczne*. Wyd. 2. C.H. Beck, Warszawa.
- Cichocki Ł., Karbownik M., 2020. *Nowe technologie a zdrowie psychiczne – szanse i trudności*. „Psychiatria”, 17(1), 41–48, <https://journals.viamedica.pl/psychiatria/article/viewFile/66116/50403> [30.04.2025].
- Cieplak T., Małyшек E., 2019. *Chmura obliczeniowa jako możliwość tworzenia zintegrowanych łańcuchów dostaw przez przedsiębiorstwa z sektora MŚP*, <https://www.logistyka.net.pl/bank-wiedzy/item/89681-chmura-obliczeniowa-jako-mozliwosc-tworzenia-zintegrowanych-lancuchow-dostaw-przez-przedsiębiorstwa-z-sektora-msp> [4.12.2024].
- Ciunovič M., 2023. *Ludzki człowiek. O rzadkim, lecz interesującym użyciu polskiego przymiotnika w zestawieniu z angielskim human*. „Poradnik Językowy”, 8, 60–71, <https://doi.org/10.33896/PorJ.2023.8.5>.
- Coleman D., Khanna R. (Eds.), 1995. *Groupware: Technologies and Applications*. Prentice Hall PTR.
- Comarch ERP Optima, 2024. <https://www.comarch.pl/erp/comarch-optima/> [11.04.2025].
- Cyrul W., Pełech-Pilichowski T., Potiopa P., 2012. *Problems of automatic processing and analysis of information from Polish legal texts*, [w:] 2012 Federated Conference on Computer Science and Information Systems (FedCSIS), 939–943, https://www.researchgate.net/publication/261058874_Problems_of_automatic_processing_and_analysis_of_information_from_Polish_legal_texts.
- Dabbish L.A., Kraut R.E., 2006. *Email Overload at Work: An Analysis of Factors Associated with Email Strain*. Banff, Alberta, Association for Computing Machinery, 431–440, <https://kraut.hciresearch.info/wp-content/uploads/dabbish06-EmailAtWork.pdf>.

- Decyzja Parlamentu Europejskiego i Rady (UE) 2022/2481 z dnia 14 grudnia 2022 r. ustanawiająca program polityki „Droga ku cyfrowej dekadzie” do 2030 r. (Dz.Urz.UE.L 2022 poz. 323).
- Decyzja Rady (UE) 2024/2218 z dnia 28 sierpnia 2024 r. w sprawie podpisania, w imieniu Unii Europejskiej, Konwencji ramowej Rady Europy w sprawie sztucznej inteligencji, praw człowieka, demokracji i praworządności (Dz.Urz.UE.L 2024 poz. 2218).
- Dennehy D., Griva A., Pouloudi N., Dwivedi Y.K., Mäntymäki M., Pappas I.O., 2022. *Artificial intelligence (AI) and information systems: perspectives to responsible AI*. „Information Systems Frontiers”, 25(1), pp. 1–7, <https://doi.org/10.1007/s10796-022-10365-3>.
- Deviniti.com, 2024. <https://deviniti.com/pl/portfolio-naszycz-realizacji/> [3.03.2025].
- DeYoung C., 2015. *Cybernetic Big Five Theory*. „Journal of Research in Personality”, 56, 33–58, <https://doi.org/10.1016/j.jrp.2014.07.004>.
- Dunn T.J., Baguley T., Brunnsden V., 2014. *From alpha to omega: A practical solution to the pervasive problem of internal consistency estimation*. „British Journal of Psychology”, 105(3), 399–412, <https://doi.org/10.1111/bjop.12046>.
- Dyrektywa Parlamentu Europejskiego i Rady (UE) 2024/2853 z dnia 23 października 2024 r. w sprawie odpowiedzialności za produkty wadliwe i uchylenia dyrektywy Rady 85/374/EWG (Dz.U.U.E.L 2024 poz. 2853).
- Empatyzer, 2025a. *Jak działa Empatyzer*, <https://empatyzer.com/pl/> [9.03.2025].
- Empatyzer, 2025b. *Psychometric measures: MBTI*, [https://empatyzer.com/disk-mtbi-4-color-test-bigfive-ocean-hexaco-or-maybe-bfas-how-to-correctly-diagnose-personality/?~:text=The psychometric measures of this,McCaulley%2C 1981#:~:text=The psychometric measures,scales \(McCaulley%2C 1981](https://empatyzer.com/disk-mtbi-4-color-test-bigfive-ocean-hexaco-or-maybe-bfas-how-to-correctly-diagnose-personality/?~:text=The%20psychometric%20measures%20of%20this,McCaulley%201981#:~:text=The%20psychometric%20measures,scales%20(McCaulley%201981) [9.03.2025].
- Empatyzer, 2025c. *DISC Assessment*, [https://empatyzer.com/disk-mtbi-4-color-test-bigfive-ocean-hexaco-or-maybe-bfas-how-to-correctly-diagnose-personality/?%23:~:text=Another test is the DISC,function in completely different ways#:~:text=Another test is,for the job](https://empatyzer.com/disk-mtbi-4-color-test-bigfive-ocean-hexaco-or-maybe-bfas-how-to-correctly-diagnose-personality/?%23:~:text=Another%20test%20is%20the%20DISC,function%20in%20completely%20different%20ways#:~:text=Another%20test%20is,for%20the%20job) [9.03.2025].
- Empatyzer, 2025d. *Selecting suitable psychometric tests*, [https://empatyzer.com/disk-mtbi-4-color-test-bigfive-ocean-hexaco-or-maybe-bfas-how-to-correctly-diagnose-personality/?%23:~:text=and only one of them,is suitable for the job#:~:text=and only one of them is suitable for the job.%C2%A0](https://empatyzer.com/disk-mtbi-4-color-test-bigfive-ocean-hexaco-or-maybe-bfas-how-to-correctly-diagnose-personality/?%23:~:text=and%20only%20one%20of%20them,is%20suitable%20for%20the%20job#:~:text=and%20only%20one%20of%20them%20is%20suitable%20for%20the%20job.%C2%A0) [9.03.2025].
- Empatyzer, 2025e. *HEXACO Model doubts*, [https://empatyzer.com/disk-mtbi-4-color-test-bigfive-ocean-hexaco-or-maybe-bfas-how-to-correctly-diagnose-personality/?%23:~:text=The most common answer#:~:text=The most common answer to these objections is the HEXACO model](https://empatyzer.com/disk-mtbi-4-color-test-bigfive-ocean-hexaco-or-maybe-bfas-how-to-correctly-diagnose-personality/?%23:~:text=The%20most%20common%20answer#:~:text=The%20most%20common%20answer%20to%20these%20objections%20is%20the%20HEXACO%20model) [9.03.2025].
- Empatyzer, 2025f. *BFAS/CB5T model*, [https://empatyzer.com/disk-mtbi-4-color-test-bigfive-ocean-hexaco-or-maybe-bfas-how-to-correctly-diagnose-personality/?%23:~:text=The most recent personality model%2C,neurotypical people#:~:text=The most recent personality model%2C developed in 2015%2C is the BFAS](https://empatyzer.com/disk-mtbi-4-color-test-bigfive-ocean-hexaco-or-maybe-bfas-how-to-correctly-diagnose-personality/?%23:~:text=The%20most%20recent%20personality%20model%2C,neurotypical%20people#:~:text=The%20most%20recent%20personality%20model%2C%20developed%20in%202015%2C%20is%20the%20BFAS) [9.03.2025].
- Empatyzer, 2025g. *Empatyzer zrewolucjonizuje komunikację w firmach*, <https://spolecznieodpowiedzialni.info/twarze-csr/empatyzer-zrewolucjonizuje-komunikacje-w-firmach> [9.03.2025].
- Erhardt J.C., 2025. *What is digital debt collection?*, <https://pairfinance.com/en/blog/what-is-digital-debt-collection/> [11.04.2025].
- Erp-view, 2025, <https://erp-view.pl/> [20.03.2025].

- Galar M., Fernández A., Barrenechea E., Bustince H., Herrera F., 2012. *A review on ensembles for the class imbalance problem: bagging-, boosting-, and hybrid-based approaches*. „IEEE Transactions on Systems, Man, and Cybernetics”, 42(4), 3358–3378, <https://doi.org/10.1109/TSMCC.2011.2161285>.
- Gartner, 2023. *Gartner Top Strategic Technology Trends for 2024*, <https://www.gartner.com/en/articles/gartner-top-10-strategic-technology-trends-for-2024> [15.12.2024].
- Gbadamosi S.L., Nwulu N.I., 2024. *Simulated blockchain-enabled peer-to-peer energy trading in marketplace*. „Przegląd Elektrotechniczny”, 100(5), 205–210, <https://doi.org/10.15199/48.2024.05.38>.
- Goodfellow I., Bengio Y., Courville A., 2016. *Deep Learning*. MIT Press.
- Grensing-Pophal L., 2023. *Using Predictive Analytics in HR*. *Society for Human Resource Management*, <https://www.shrm.org/topics-tools/news/technology/using-predictive-analytics-in-hr> [9.03.2025].
- He H., Garcia E.A., 2009. *Learning from Imbalanced Data*. „IEEE Transactions on Knowledge and Data Engineering”, 21(9), 1263–1284, <https://doi.org/10.1109/TKDE.2008.239>.
- He H., Bai Y., Garcia E., Li S., 2008. *ADASYN: Adaptive synthetic sampling approach for imbalanced learning*, [w:] *Proceedings of the 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*, Hong Kong, 1322–1328, <https://doi.org/10.1109/IJCNN.2008.4633969>.
- Hryniewicz K., 2025. *Wyciskanie sensu z alfy Cronbacha*, <https://nauka.metodolog.pl/wyciskanie-sensu-z-alfy-cronbacha-analiza-rzetelnosci/> [9.03.2025].
- IBM SPSS, 2025. *Reliability Analysis*, <https://www.ibm.com/docs/en/spss-statistics/30.0.0?topic=analysis-reliability-statistics> [9.03.2025].
- IBM Submission to the European Commission on the Draft Artificial Intelligence Act, 2021; feedback from IBM, https://ec.europa.eu/info/law/better-regulation/have-your-say/initiatives/12527-Artificial-intelligence-ethical-and-legal-requirements/F2665615_en [30.04.2025].
- JADEF, 2023. *JAVA Agent DEvelopment Framework*, <https://jade.tilab.com/> [4.04.2025].
- Jagielski M., 2018. *Rola i znaczenie zarządzania wiedzą dla przedsiębiorstw z sektora MSP*. „Acta Universitatis Nicolai Copernici. Zarządzanie”, 45(2), 99–111, https://doi.org/10.12775/AUNC_ZARZ.2018.024.
- Jankowski A., 2025. *Analiza rzetelności Alfa Cronbacha. Teoria, wyjaśnienia, przykłady*, <https://www.slideshare.net/slideshow/analiza-rzetelnosci-alfa-cronbacha-teoria-wyjanienia-przykady/pdf/255428964> [9.03.2025].
- Jankowski R., 2023. *Zarządzanie wierzytelnościami masowymi w podmiocie windykacyjnym* [rozprawa doktorska]. Akademia Górniczo-Hutnicza, Kraków.
- Jankowski R., Paliński A. 2024a. *Debt collection model for mass receivables based on decision rules – A path to efficiency and sustainability*. „Sustainability”, 16(14), 5885, <https://doi.org/10.3390/su16145885>.
- Jankowski R., Paliński A., 2024b. *Zarządzanie procesem windykacji wierzytelności masowych. Integracja uczenia maszynowego z wiedzą ekspercką*. Wydawnictwa AGH, Kraków, <https://doi.org/10.7494/978-83-68219-29-6>.
- Judge T.A., Higgins Ch.A., Thoresen C.J., Barrick M.R., 1999. *The Big Five personality traits, general mental ability, and career success across the life span*. „Personnel Psychology”, 52(3), 621–652, <https://doi.org/10.1111/j.1744-6570.1999.tb00174.x>.

- Jurkiewicz R., 2013. *Wierzytelność i dług: aspekty prawne i podatkowe*. Wolters Kluwer Polska, Warszawa.
- Kaggle, 2025. <https://www.kaggle.com/datasets/mrferozi/loan-raw/data> [20.02.2025].
- Kaplan J., McCandlish S., Henighan T., Brown T., Chess B., Child R., Gray S., Radford A., Wu J., Amodei D., 2020. *Scaling Laws for Neural Language Models*, <https://doi.org/10.48550/arXiv.2001.08361>.
- Karl K.A., Peluchette, J.V., Aghakhani N. 2022. *Virtual work meetings during the COVID-19 pandemic: The good, bad, and ugly*. „Small Group Research”, 53(3), 343–365, <https://doi.org/10.1177/10464964211015286>.
- Kimball R., Ross M., 2013. *The Data Warehouse Toolkit: The Definitive Guide to Dimensional Modeling*. Third Edition. Wiley.
- Komisja Europejska, 2003. *Zalecenie 2003/361/WE z dnia 6 maja 2003 r. dotyczące definicji przedsiębiorstw mikro-, małych i średnich* (Dz.Urz.UE.L 124 z 20.05.2003) <http://data.europa.eu/eli/reco/2003/361/oj>.
- Komisja Europejska, 2018. *Komunikat Komisji do Parlamentu Europejskiego, Rady Europejskiej, Europejskiego Komitetu Ekonomiczno-Społecznego i Komitetu Regionów: Sztuczna inteligencja dla Europy* (COM/2018/137 final), <https://eur-lex.europa.eu/legal-content/PL/TXT/?uri=COM%3A2018%3A237%3AFIN> [7.12.2024].
- Komisja Europejska, 2020. *Biała Księga w sprawie sztucznej inteligencji. Europejskie podejście do doskonałości i zaufania* (COM/2020/65 final), <https://eur-lex.europa.eu/legal-content/PL/ALL/?uri=CELEX:52020DC0065> [1.12.2024].
- Komisja Europejska, 2024. *Komisja podpisała Konwencję ramową Rady Europy o sztucznej inteligencji i prawach człowieka, demokracji i praworządności, komunikat z dnia 5 września 2024 r.*, <https://digital-strategy.ec.europa.eu/pl/news/commission-signed-council-europe-framework-convention-artificial-intelligence-and-human-rights> [8.12.2024].
- Komisja Europejska, *Kształtowanie cyfrowej przyszłości Europy*, <https://digital-strategy.ec.europa.eu/pl> [7.12.2024].
- Kondracki S., 2023. *31,2 miliarda dolarów dodatkowego zysku rocznego na horyzoncie? Implikacje dla branży windykacyjnej*, <https://zpf.pl/312-miliarda-dolarow-dodatkowego-zysku-rocznego-na-horyzoncie> [3.03.2024].
- Kostrzewa Ł., Nowak R., 2022. *Polish court ruling classification using deep neural networks*. „Sensors”, 22(6), 2137, <https://doi.org/10.3390/s22062137>.
- Krasuski A., 2021. *Status prawny sztucznego agenta. Podstawy prawne zastosowania sztucznej inteligencji*. C.H. Beck, Warszawa.
- Krawczyk B., 2016. *Learning from imbalanced data: open challenges and future directions*. „Progress in Artificial Intelligence”, 5, 221–232, <https://doi.org/10.1007/s13748-016-0094-0>.
- Krzemiński D., 2022. *SAP Receivables Management*, <https://www.bpxglobal.com/sap-collections-management/> [11.04.2025].
- Kulkarni P., 2024. *Leveraging AI-Powered OCR in the Legal Industry: Benefits, Use Cases, and Best Solutions*, <https://hyperverge.co/blog/ocr-legal-documents/> [7.04.2025].
- Laarabi M., Maach A., Senhaji Hafid A., 2020. *Smart contracts and over-enforcement: Analytical considerations on smart contracts as legal contracts*, [w:] *2020 1st International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET)*, <https://doi.org/10.1109/IRASET48871.2020.9092138>.

- Lachiewicz S., Matejun M., Mikoláš Z., 2021. *Okazje w zarządzaniu innowacjami w firmach sektora MŚP*. CeDeWu, Warszawa.
- Lai L., Świerczyński M. (red.), 2020. *Prawo sztucznej inteligencji*. C.H. Beck, Warszawa
- Laudon K.C., Laudon J.P., 2020. *Management Information Systems: Managing the Digital Firm*. 16th Edition. Pearson Education, Harlow.
- Leonardi P.M., Huysman M., Steinfield Ch., 2013. *Enterprise social media: definition, history, and prospects for the study of social technologies in organizations*. „Journal of Computer-Mediated Communication”, 19(1), 1–19, <https://doi.org/10.1111/jcc4.12029>.
- Licznik Elektromobilności I, 2025. *Rynek odczuwa brak ścieżki leasingowej programu „Mój elektryk”*, <https://psnm.org/2024/informacja/licznik-elektromobilnosci-rynek-odczuwa-brak-sciezki-leasingowej-programu-moj-elektryk/> [3.02.2025].
- Licznik Elektromobilności II, 2025. *2023 dobrym rokiem dla sektora e-mobility*, <https://psnm.org/2023/informacja/licznik-elektromobilnosci-2023-dobrym-rokiem-dla-sektora-e-mobility/> [3.02.2025].
- Licznik Elektromobilności III, 2025. *Po polskich drogach jeździ więcej osobowych BEV niż PHEV*, <https://psnm.org/2022/informacja/licznik-elektromobilnosci-po-polskich-drogach-jezdzi-wiecej-osobowych-bev-niz-phev/> [3.02.2025].
- Maalouf M., Trafalis T.B., 2011. *Rare events and imbalanced datasets: an overview*. „International Journal of Data Mining, Modelling and Management”, 3(4), 375–388, <https://doi.org/10.13140/RG.2.1.4088.1367>.
- Mahani A., Ali A., 2019. *Classification Problem in Imbalanced Datasets*, [w:] A. Sadollah, T.S. Sinha (Eds.), *Recent Trends in Computational Intelligence*, IntechOpen, <https://doi.org/10.5772/intechopen.89603>.
- Matiolański A., 2023. *Współczesne architektury systemów opartych o mikroserwisy*. „Przeгляд Telekomunikacyjny – Wiadomości Telekomunikacyjne”, 4, 49–52, <https://doi.org/10.15199/59.2023.4.6>.
- McCrae R.R., Costa P.T., 1989. *Reinterpreting the Myers–Briggs type indicator from the perspective of the Five-Factor Model of Personality*. „Journal of Personality”, 57(1), 17–40, <https://doi.org/10.1111/j.1467-6494.1989.tb00759.x>.
- McKinsey, 2022. *The state of AI in 2022—and a half decade in review*, <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-in-2022-and-a-half-decade-in-review> [11.04.2025].
- McKinsey, 2025. *The state of AI: How organizations are rewiring to capture value*, <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai> [11.04.2025].
- Menardi G., Torelli N., 2014. *Training and assessing classification rules with imbalanced data*. „Data Mining and Knowledge Discovery”, 28, 92–122, <https://doi.org/10.1007/s10618-012-0295-5>.
- Mendrek A., 2021. *Odmienny standard ochrony prawnej w elektronicznym postępowaniu upominawczym – uzasadniona potrzeba czy arbitralność ustawodawcy?* „Acta Iuridica Resoviensia”, 1(32), 123–135, <https://doi.org/10.15584/actaires.2021.1.9>.
- Mereu A., 2021. *Big Five personality traits prediction with AI*. „European Psychiatry”, 64(1), 445–446.
- Michalak A., 2021. *Odpowiedzialność cywilnoprawna w obrocie oprogramowaniem komputerowym w erze sztucznej inteligencji*. C.H. Beck, Warszawa.

- Michałowicz A., 2021. *Przetwarzanie danych biometrycznych a ochrona jednostek – analiza wybranych zagadnień na tle ogólnego rozporządzenia o ochronie danych i projektu aktu w sprawie sztucznej inteligencji*. IKAR, 10(6), 78–94, <https://doi.org/10.7172/2299-5749.IKAR.6.10.5>.
- Mikutowski M., 2024. *Portfel wiarygodności niebankowych. Rynek, metody i determinanty wyceny*. Wydawnictwo Uniwersytetu Ekonomicznego w Poznaniu, <https://doi.org/10.18559/978-83-8211-248-1>.
- Misiuro T., 2017. *Modele osobowości w psychologii*. „Psychologiczne Zeszyty Naukowe. Półrocznik Instytutu Psychologii Uniwersytetu Zielonogórskiego”, 2, 163–177, https://zbc.uz.zgora.pl/Content/54376/10_misiuro_modele.pdf [9.03.2025].
- Mohanta B.K., Panda S.S., Jena D., 2019. *An overview of smart contract and use cases in blockchain technology*, [w:] *2018 9th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, Bengaluru, India, <https://doi.org/10.1109/ICCCNT.2018.8494045>.
- Morawiec P., 2024. *Rozwój zrównoważonych technologii informatycznych w perspektywie czwartej rewolucji przemysłowej*, [w:] M. Chodyka (red. nauk.), *Spółeczeństwo – Technologia – Gospodarka. Nowoczesne technologie na rzecz rozwoju społeczno-gospodarczego*, tom 1, Akademia Białska im. Jana Pawła II, Biała Podlaska, 24–38.
- Myers I.B., McCaulley M.H., Quenk N.L., Hammer A.L., 1985. *Manual: A Guide to the Development and Use of the Myers–Briggs Type Indicator*. Second Edition., Consulting Psychologists Press, Palo Alto.
- Niedopytalski M., 2024. *Blockchain i sztuczna inteligencja w ochronie danych: bezpieczne przechowywanie i analiza*, <https://mostwiedzy.pl/pl/publication/blockchain-i-sztuczna-inteligencja-w-ochronie-danych-bezpieczne-przechowywanie-i-analiza,202412231726050033201-0> [15.04.2025].
- Nogalski B., Karpacz J., Wójcik-Karpacz A., 2004. *Funkcjonowanie i rozwój małych i średnich przedsiębiorstw. Od czego to zależy?* Oficyna Wydawnicza AJG, Bydgoszcz.
- Nour M., Said S.M., Ali A., Farkas C., 2019. *Smart charging of electric vehicles according to electricity price*, [w:] *2019 International Conference on Innovative Trends in Computer Engineering (ITCE)*, <https://doi.org/10.1109/ITCE.2019.8646425>.
- Ou C.X., 2010. *The Impact of Instant Messaging in the Workplace*. Americas Conference on Information Systems, <https://api.semanticscholar.org/CorpusID:8797107>.
- Oyekunle D., Boohene D., 2024. *Digital transformation potential: The role of Artificial Intelligence in business*. „International Journal of Professional Business Review”, 9(3), <https://doi.org/10.26668/businessreview/2024.v9i3.4499>.
- Paliński A., 2013a. *Analiza ekonomicznych warunków umowy kredytowej w ujęciu teorii gier*. Uczelniane Wydawnictwo Uniwersytetu Ekonomicznego w Katowicach, Katowice.
- Paliński A., 2013b. *Wpływ wartości likwidacyjnej aktywów firmy na oprocentowanie kredytu bankowego – wyniki badań polskich spółek giełdowych*. „Bank i Kredyt”, 44(2), 207–236, https://bankandcredit.nbp.pl/content/2013/02/bik_02_2013_04_art.pdf [14.04.2025].
- Peters G.-J.Y., 2014. *The alpha and the omega of scale reliability and validity: Why and how to abandon Cronbach's alpha and the route towards more comprehensive assessment of scale quality*. „The European Health Psychologist”, 16(2), 56–69, <https://doi.org/10.31234/osf.io/h47fv>.
- Pilarz J., 2025. *Analizy statystyczne a psychometria*, <https://www.badania-statystyczne.pl/analizy-statystyczne-a-psychometria> [9.03.2025].

- PolDeepNer2, 2022. <https://github.com/CLARIN-PL/PolDeepNer2> [11.03.2025].
- Potiopa P., Karwatowski M., Duda J., Sasor P., Wielgosz M., Muzykiewicz B., 2017. *Semantic search extension based on polish wordnet relations in business document exploration*, [w:] *Proceedings of the 1st International Conference on Internet of Things and Machine Learning*, <https://doi.org/10.1145/3109761.3158401>.
- Prymon-Ryś E., 2023. *Implementation and evaluation of a selected CRM tool for the management of stakeholder relations in an innovative student project*. „Marketing of Scientific and Research Organizations”, 49(3), 123–140, <https://doi.org/10.2478/minib-2023-0018>.
- Radicati Group., 2023. *Email Statistics Report, 2023–2027*, <https://www.radicati.com/?p=18089>.
- RESPO, 2024. *Windykacja – co to? Etapy procesu windykacyjnego*, <https://kancelariarespo.pl/blog/windykacja-sadowa-jak-przebiega/> [2.04.2025].
- Rezolucja Parlamentu Europejskiego z dnia 16 lutego 2017 r. zawierająca zalecenia dla Komisji w sprawie przepisów prawa cywilnego dotyczących robotyki (2018/C 252/25).
- Rezolucja Parlamentu Europejskiego z dnia 20 października 2020 r. z zaleceniami dla Komisji w sprawie systemu odpowiedzialności cywilnej za sztuczną inteligencję (2020/2014(INL)) (Dz.Urz.U.E.C 2021 404/107).
- Rezolucja Parlamentu Europejskiego z dnia 20 października 2020 r. zawierająca zalecenia dla Komisji w sprawie ram aspektów etycznych sztucznej inteligencji, robotyki i powiązanych z nimi technologii (2020/2012(INL)) (Dz.Urz.U.E.C 2021 404/63).
- Rezolucja Parlamentu Europejskiego z dnia 20 października 2020 r. w sprawie praw własności intelektualnej w dziedzinie rozwoju technologii sztucznej inteligencji (2020/2015(INI)) (Dz.Urz.U.E.C 2021 404/129).
- Rezolucja Parlamentu Europejskiego z dnia 3 maja 2022 r. w sprawie sztucznej inteligencji w epoce cyfrowej (Dz.Urz.U.E.C 465/65).
- Rojek-Socha P., Sewastianowicz M., 2023. *ChatGPT prawnikom może pomóc, ale jest ryzyko dla tajemnic klientów*, <https://www.prawo.pl/prawnicy-sady/chatgpt-a-kancelarie-adwokackie-i-radcowskie,521306.html> [4.04.2025].
- Rozporządzenie Parlamentu Europejskiego i Rady (UE) 2021/694 z dnia 29 kwietnia 2021 r. ustanawiające program „Cyfrowa Europa” oraz uchylające decyzję (UE) 2015/2240 (Dz.Urz.U.E.L 2024.166).
- 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) (Dz.Urz.U.E.L 2024.1689).
- Satow L., 2021. *Reliability and Validity of the Enhanced Big Five Personality Test (B5T)* [preprint], <https://doi.org/10.31234/osf.io/wsugv>.
- Scikit-learn, 2025. <https://scikit-learn.org/stable/> [14.04.2025].
- SHAIP, 2025. *Co to jest rozpoznawanie jednostek nazwanych (NER) – przykłady, przypadki użycia, korzyści i wyzwania* <https://pl.shaip.com/blog/named-entity-recognition-and-its-types/> [17.03.2025].
- Shamsuzzoha A., Jaakkola T., 2024. *The scope of demand-driven material requirements planning in operative purchasing of a multi-national company: A case study*. „International Journal of Engineering and Business Management”, 16, <https://doi.org/10.1177/18479790241293890>.

- Shanmugamani K., Mohamad F., 2023. *The implementation of warehouse management system (WMS) to improve warehouse performance in business to business (B2B)*. „International Journal of Industrial Management”, 17(4), 231–239, <https://doi.org/10.15282/ijim.17.4.2023.10091>.
- Show-Jane Y., Yue-Shi L., 2009. *Cluster-based under-sampling approaches for imbalanced data distributions*. „Expert Systems with Applications”, 36(3), 5718–5727, <https://doi.org/10.1016/j.eswa.2008.06.108>.
- Shukla D., Dwivedi S.K., 2025. *Sentiment analysis versus aspect-based sentiment analysis versus emotion analysis from text: a comparative study*. „International Journal of System Assurance Engineering and Management”, 16(23), 512–531, <https://doi.org/10.1007/s13198-024-02666-4>.
- Skowrońska A. (red.), 2023. *Raport o stanie sektora małych i średnich przedsiębiorstw w Polsce*. Polska Agencja Rozwoju Przedsiębiorczości, Warszawa.
- Sussman A.L., 2025. *AI Photo Analysis Illuminates How Personality Traits Predict Career Trajectories*, <https://insights.som.yale.edu/insights/ai-photo-analysis-illuminates-how-personality-traits-predict-career-trajectories> [9.03.2025].
- Traktat o funkcjonowaniu Unii Europejskiej (Dz.Urz.U.E.C 2012 Nr 326, s. 47).
- Turkle S., 2017. *Alone Together: Why We Expect More from Technology and Less from Each Other*. Third Edition. Basic Books, New York.
- Vujović Z.D., 2021. *Classification model evaluation metrics*. „International Journal of Advanced Computer Science and Applications”, 12(6), <https://doi.org/10.14569/IJACSA.2021.0120670>.
- Wejer-Kudelko M., Kudelko M., 2017. *Wdrożenie koncepcji CRM w procesie windykacji należności – analiza przypadku*. „Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu”, 475, 357–367, <https://doi.org/10.15611/pn.2017.475.30>.
- Wendehorst C., 2022. *Liability for Artificial Intelligence: The Need to Address both Safety Risks and Fundamental Rights Risks*, [w:] S. Voeneky, P. Kellmeyer, O. Mueller, W. Burgard (Eds.), *The Cambridge Handbook of Responsible Artificial Intelligence Interdisciplinary Perspectives*. Cambridge University Press, 187–209, <https://doi.org/10.1017/9781009207898.016>.
- Wilk-Nawrot I., 2024. *Windykacja należności – praktyczny przewodnik*, <https://indos.pl/blog/windykacja/> [7.04.2025].
- Zhang J., Mani I., 2003. *kNN approach to unbalanced data distributions: a case study involving information extraction*, [w:] T. Fawcett, N. Mishra (Eds.) *ICML'03: Proceedings of the Twentieth International Conference on Machine Learning*, Washington DC, August 21–24 2003, <https://www.site.uottawa.ca/~nat/Workshop2003/jzhang.pdf> [14.04.2025].
- Zheng X., 2020. *SMOTE Variants for Imbalanced Binary Classification: Heart Disease Prediction*. University of California, Los Angeles, UCLA Electronic Theses and Dissertations, <https://escholarship.org/uc/item/99x0w9w0> [20.03.2025].
- Zielińska A., 2019. *Model for settlement electric vehicles charging and financing infrastructure for charging them with the support of blockchain environment*. „Przegląd Elektrotechniczny”, 95(12), <https://doi.org/10.15199/48.2019.12.54>.
- Zielińska A., 2020. *Application possibilities of blockchain technology in the energy*. „E3S Web Conferences”, 154, 07003, <https://doi.org/10.1051/e3sconf/202015407003>.
- Zielińska A., 2021. *Possibilities of using blockchain technology in the area of electricity trade settlements*. „Przegląd Elektrotechniczny”, 97(12), <https://doi.org/10.15199/48.2021.12.32>.

- Ziemba E., 2017. *The contribution of ICT adoption to the sustainable information society*. „Journal of Computer Information Systems”, 53(3), 116–126 <https://doi.org/10.1080/08874417.2017.1312635>.
- Ziemba E., Obłąk I., 2012. *Systemy informatyczne w organizacjach zorientowanych procesowo*. „Problemy Zarządzania”, 10(3), 8–24, https://bazhum.muzhp.pl/media/texts/problemy-zarzadzania/2012-tom-10-numer-3/problemy_zarzadzania-r2012-t10-n3-s8-24.pdf [11.04.2025].
- Zinbarg R.E., Revenelle W., Yovel I., Li W., 2005. *Cronbach's α , Revelle's β , and McDonald's ω_H : Their relations with each other and two alternative conceptualizations of reliability*. „psychometrika”, 70(1), 123–133, <https://doi.org/10.1007/s11336-003-0974-7>.