



Złożenie pracy online:  
2026-02-24 14:31:55  
Kod pracy:  
54253/51833/CloudA

Nikola Kubik  
(nr albumu: 34974 )

Praca magisterska

## **Wykorzystanie sztucznej inteligencji w controllingu finansowym - szanse, zagrożenia i kierunki rozwoju**

## **The Application of Artificial Intelligence in Financial Controlling - Opportunities, Risks and Future Development Directions**

Wydział: Wyższa Szkoła Biznesu - National-Louis University

Kierunek: Zarządzanie

Specjalność: rachunkowość i controlling

Promotor: dr Bartłomiej Bartnik

Składam serdeczne podziękowania Panu Promotorowi dr. Bartłomiejowi Bartnikowi za merytoryczne wsparcie, cenne wskazówki oraz poświęcony czas w trakcie przygotowywania niniejszej pracy magisterskiej. Dziękuję za życzliwość, zaangażowanie oraz inspirujące uwagi, które pozwoliły mi uporządkować i pogłębić analizowane zagadnienia.



## Streszczenie

Praca dotyczy wykorzystania sztucznej inteligencji w controllingu finansowym oraz analizie jej szans, zagrożeń i kierunków dalszego rozwoju w przedsiębiorstwach działających w Polsce. Badania przeprowadzono w oparciu o przegląd literatury naukowej i raportów branżowych, ankietę internetową wśród 100 specjalistów finansów i controllingu oraz wywiad półustrukturyzowany z ekspertem-praktykiem, a uzyskane dane poddano analizie statystycznej i jakościowej. Wyniki wskazują, że AI jest najczęściej wykorzystywana w prognozowaniu, analizie odchyleń oraz automatyzacji raportowania i przyczynia się do skrócenia czasu przygotowania analiz oraz poprawy ich trafności. Respondenci postrzegają sztuczną inteligencję przede wszystkim jako narzędzie zwiększające efektywność pracy controllera, choć równocześnie dostrzegają ryzyka związane z jakością danych, ograniczoną wyjaśnialnością modeli oraz możliwością nadmiernego zaufania do wyników systemów. Badania potwierdzają, że AI nie zastępuje controllera, lecz zmienia charakter jego pracy w kierunku roli bardziej analitycznej i doradczej, a skuteczne wdrożenie wymaga odpowiedniego przygotowania danych, kompetencji zespołu oraz zachowania kontroli nad procesem decyzyjnym.

## Słowa kluczowe

sztuczna inteligencja, controlling finansowy, prognozowanie, automatyzacja raportowania, analiza odchyleń, badania ankietowe, wywiad ekspercki

## Abstract

The thesis examines the use of artificial intelligence in financial controlling, focusing on its opportunities, risks and future development directions in companies operating in Poland. The research was based on a review of academic literature and industry reports, an online survey conducted among 100 finance and controlling professionals, and a semi-structured expert interview; the collected data were analyzed using statistical and qualitative methods. The results indicate that AI is most commonly applied in forecasting, variance analysis and reporting automation, contributing to reduced reporting time and improved analytical accuracy. Respondents perceive artificial intelligence primarily as a tool that enhances controller efficiency, while also recognizing risks related to data quality, limited model explainability and excessive reliance on automated outputs. The findings confirm that AI does not replace controllers but transforms their role towards more analytical and advisory responsibilities, and that effective implementation requires proper data governance, adequate competencies and maintained human oversight over decision-making processes.

## Keywords

artificial intelligence, financial controlling, forecasting, reporting automation, variance analysis, survey research, expert interview



## SPIS TREŚCI

WSTĘP .....	3
ROZDZIAŁ 1. WPROWADZENIE DO CONTROLLINGU FINANSOWEGO.....	9
1.1. Pojęcie controllingu i jego ewolucja – definicje, geneza oraz rozwój koncepcji controllingu ....	9
1.2 Rola controllingu finansowego w przedsiębiorstwie – miejsce w strukturze organizacyjnej oraz znaczenie dla podejmowania decyzji .....	10
1.3 Kluczowe funkcje i zadania controllingu – budżetowanie, planowanie, kontrola kosztów, analiza odchyleń i raportowanie .....	12
1.4 Narzędzia i metody controllingu finansowego – podstawowe techniki, modele analityczne oraz systemy informatyczne wspierające controlling.....	14
1.5 Wyzwania i kierunki rozwoju controllingu – rosnące znaczenie danych, cyfryzacja, nowe kompetencje controllerów .....	16
ROZDZIAŁ 2. TEORETYCZNE PODSTAWY SZTUCZNEJ INTELIGENCJI I JEJ ZASTOSOWANIA W FINANSACH .....	19
2.1 Definicja i krótka historia sztucznej inteligencji – zarys pojęcia AI, najważniejsze etapy rozwoju .....	19
2.2 Główne koncepcje i rodzaje AI – uczenie maszynowe, uczenie głębokie i robotyzacja procesów .....	21
2.3 Zastosowania AI w finansach – główne obszary i przykłady wykorzystania .....	23
2.4 Korzyści i ograniczenia wykorzystania AI w finansach – perspektywa praktyczna.....	25
2.5 Aspekty etyczne i prawne wykorzystania AI w finansach – odpowiedzialność, przejrzystość i kontrola.....	27
ROZDZIAŁ 3. OBSZARY CONTROLLINGU WSPIERANE PRZEZ AI – ANALIZA LITERATURY I RAPORTÓW .....	29
3.1 Prognozowanie i planowanie z wykorzystaniem AI .....	29
3.2 Automatyzacja procesów budżetowych i raportowania – przykłady narzędzi, które usprawniają tworzenie zestawień i raportów.....	30
3.3 Analiza rentowności i controlling kosztów – rola AI w identyfikacji kosztów, analizie rentowności i optymalizacji marż.....	31
3.4 Zarządzanie ryzykiem i płynnością – wykorzystanie modeli predykcyjnych do oceny ryzyka i monitorowania płynności .....	32
3.5 Monitoring należności i płatności – zastosowanie AI w ograniczaniu ryzyka zatorów płatniczych .....	33
3.6 Przegląd literatury i raportów branżowych – podsumowanie najnowszych wyników badań i raportów dotyczących AI w controllingu.....	34
ROZDZIAŁ 4. BADANIA WŁASNE: METODOLOGIA I ANALIZA WYNIKÓW ANKIETY .....	38
4.1 Metodologia badań własnych.....	38
4.1.1 Charakterystyka ankiety.....	38
4.1.2 Charakterystyka wywiadu.....	39



4.2 Analiza wyników badania ankietowego i wywiadu .....	39
4.2.1 Wyniki badania ankietowego – ujęcie ogólne .....	39
4.2.2 Wnioski z wywiadu eksperckiego .....	40
4.3 Charakterystyka próby badawczej.....	40
4.4 Analiza wyników ankiety – poziom wykorzystania AI w controllingu finansowym.....	42
4.4.1 Etap wykorzystania AI w organizacjach.....	42
4.4.2 Dojrzałość danych a poziom wykorzystania AI .....	44
4.4.3 Korzyści i ryzyka w kontekście wykorzystania AI.....	44
4.4.4 Podsumowanie .....	45
4.5 Analiza wyników wywiadu .....	46
4.6 Synteza wyników i porównanie z literaturą .....	49
<b>ROZDZIAŁ 5. WNIOSKI I REKOMENDACJE DOTYCZĄCE WDRAŻANIA AI W CONTROLLINGU.....</b>	<b>52</b>
5.1 Podsumowanie wyników pracy .....	52
5.2 Ocena korzyści i ryzyk wdrożenia AI .....	53
5.3 Rekomendacje dla przedsiębiorstw dotyczące wdrażania AI w controllingu finansowym.....	55
5.4 Perspektywy i kierunki dalszego rozwoju.....	57
5.5 Ograniczenia badań i propozycje przyszłych prac .....	58
<b>BIBLIOGRAFIA.....</b>	<b>59</b>
<b>Spis rysunków: .....</b>	<b>64</b>
Rysunek 4.1 Etap wykorzystania AI w organizacjach .....	64
Rysunek 4.2 Częstotliwość korzystania z narzędzi AI w pracy .....	64
Rysunek 4.3 Średnia ocena jakości danych w zależności od etapu wykorzystania AI .....	64
Rysunek 4.4 Porównanie średniej oceny korzyści i ryzyk związanych z AI .....	64
Rysunek 4.5 Porównanie czasu przygotowania raportów przed i po wdrożeniu AI.....	64
<b>Załączniki: .....</b>	<b>65</b>
Załącznik 1. Ankieta do pracy: „Wykorzystanie AI w controllingu finansowym - szanse, zagrożenia i kierunki rozwoju”.....	65
Załącznik 2. Scenariusz wywiadu półustrukturyzowanego.....	70
Załącznik 3. Wywiad z ekspertem - zapis rozmowy .....	73



## WSTĘP

Celem niniejszej pracy magisterskiej jest analiza możliwości, ograniczeń oraz przyszłych kierunków zastosowania sztucznej inteligencji w controllingu finansowym. Podejmę próbę szczegółowego przedstawienia, w jakim stopniu narzędzia AI wspierają obecnie procesy controllingowe, jakie obszary są najbardziej podatne na automatyzację oraz w jaki sposób sztuczna inteligencja może zwiększyć efektywność analiz finansowych. Istotnym elementem pracy będzie także identyfikacja potencjalnych zagrożeń związanych z wdrażaniem rozwiązań opartych na AI, takich jak ryzyko utraty kontroli nad procesami analitycznymi czy niepewność co do jakości danych generowanych automatycznie.

Przeprowadzone badania pozwolą wskazać kluczowe bariery technologiczne, organizacyjne i kompetencyjne, które ograniczają zastosowanie sztucznej inteligencji w działach finansowych. Dzięki temu możliwe będzie sformułowanie rekomendacji dotyczących przyszłych strategii wdrożeniowych oraz określenie warunków, jakie muszą zostać spełnione, aby maksymalnie wykorzystać potencjał sztucznej inteligencji w controllingu finansowym.

Główną motywacją do podjęcia tematyki zastosowania sztucznej inteligencji w controllingu finansowym było rosnące znaczenie narzędzi cyfrowych oraz automatyzacji procesów analitycznych w nowoczesnym biznesie. Dynamiczny rozwój technologiczny, jaki można zaobserwować w ostatnich latach, coraz silniej wpływa na charakter pracy w działach finansowych, zmieniając dotychczasowe metody działania oraz sposób podejmowania decyzji przez menedżerów. Jako osoba zawodowo związana z obszarem finansów oraz rachunkowości, dostrzegam na co dzień potencjał oraz jednocześnie pewne trudności, jakie wiążą się z implementacją rozwiązań AI w praktyce biznesowej.

Dodatkowym impulsem do podjęcia tematu była obserwacja, iż specjaliści pracujący w obszarach controllingowych często posiadają ambiwalentny stosunek do automatyzacji – doceniają jej zalety, takie jak szybkość, precyzja czy dostępność danych w czasie rzeczywistym, jednocześnie obawiając się potencjalnych błędów, utraty kontroli czy zagrożeń związanych z niewystarczającym poziomem kompetencji technologicznych.

Temat ten jest również niezwykle aktualny z perspektywy przyszłościowej – wiele raportów branżowych i opracowań eksperckich wskazuje na coraz szersze wykorzystanie sztucznej inteligencji jako nieunikniony trend, który wymaga od specjalistów ciągłego pogłębiania wiedzy oraz adaptowania się do zmieniających się realiów rynku pracy.



Wszystkie te aspekty zainspirowały mnie do przeprowadzenia badań, których celem jest lepsze zrozumienie możliwości, jakie sztuczna inteligencja niesie dla controllingu finansowego oraz wskazanie konkretnych obszarów wymagających szczególnej uwagi w procesach wdrożeniowych.

Cele szczegółowe badań:

1. W ramach realizacji głównego celu pracy magisterskiej, dotyczącego analizy zastosowania sztucznej inteligencji w controllingu finansowym, sformułowano następujące cele szczegółowe:
2. Identyfikacja obszarów controllingu finansowego, w których obecnie wykorzystywane są narzędzia sztucznej inteligencji.
3. Celem jest ustalenie, jakie procesy controllingowe najczęściej są wspierane przez AI, z uwzględnieniem przykładów zastosowań praktycznych w działach finansowych przedsiębiorstw działających w Polsce.
4. Ocena poziomu wiedzy i zaufania specjalistów z dziedziny controllingu do rozwiązań opartych na sztucznej inteligencji.
5. Cel ten koncentruje się na analizie świadomości ekspertów z zakresu finansów dotyczącej narzędzi AI oraz stopnia ich gotowości do integracji nowych technologii z tradycyjnymi metodami pracy.
6. Analiza potencjalnych korzyści oraz zagrożeń wynikających z automatyzacji procesów controllingowych z wykorzystaniem AI.
7. Chodzi tutaj o szczegółowe wskazanie zalet, takich jak zwiększona efektywność, szybkość działania czy lepsza predykcyjność, jak również określenie ryzyk, takich jak błędy algorytmów, problemy z danymi czy możliwość utraty kontroli nad procesami.
8. Wskazanie barier wdrażania rozwiązań opartych na sztucznej inteligencji w działach finansowych.
9. Cel ten zakłada ustalenie kluczowych ograniczeń technologicznych, organizacyjnych oraz kompetencyjnych, które utrudniają efektywne i szerokie wykorzystanie narzędzi AI w praktyce controllingowej.
10. Realizacja powyższych celów szczegółowych pozwoli na uzyskanie kompleksowego obrazu aktualnego stanu wykorzystania AI w controllingu finansowym oraz stworzenie podstaw do sformułowania praktycznych rekomendacji dla firm zainteresowanych wdrożeniem tego typu rozwiązań.



Tematyka wykorzystania sztucznej inteligencji w controllingu finansowym jest niezwykle aktualnym zagadnieniem, coraz szerzej dyskutowanym zarówno w środowisku naukowym, jak i biznesowym. Postępująca cyfryzacja, rozwój technologii uczenia maszynowego oraz wzrost znaczenia automatyzacji sprawiają, że przedsiębiorstwa chętniej sięgają po rozwiązania oparte na zaawansowanych algorytmach, aby usprawnić swoje procesy analityczne oraz zwiększyć efektywność podejmowanych decyzji.

Coraz większa ilość danych finansowych generowanych każdego dnia wymusza na specjalistach ds. controllingu konieczność stosowania nowoczesnych technologii, które umożliwiają szybkie, precyzyjne i dogłębne analizy. Zastosowanie sztucznej inteligencji pozwala na automatyzację rutynowych zadań, takich jak raportowanie finansowe czy prognozowanie wyników, dzięki czemu eksperci mogą skoncentrować się na strategicznych aspektach zarządzania finansami.

Zainteresowanie rozwiązaniami opartymi na AI jest także konsekwencją coraz częściej dostrzeganego potencjału technologii w zakresie poprawy jakości decyzji zarządczych, szczególnie w kontekście dynamicznego środowiska biznesowego i zmienności rynków finansowych. Jednocześnie temat ten jest interesujący również ze względu na pojawiające się kontrowersje dotyczące ryzyk związanych z wdrażaniem nowych technologii, takich jak utrata kontroli nad procesami analitycznymi, błędy algorytmiczne czy etyczne aspekty automatyzacji.

W związku z powyższym, dogłębne zbadanie zagadnienia zastosowania sztucznej inteligencji w controllingu finansowym oraz wskazanie konkretnych obszarów jej efektywnego wdrażania stanowi istotny wkład w rozwój zarówno teorii, jak i praktyki zarządzania finansowego w przedsiębiorstwach.

Niniejsza praca magisterska została podzielona na pięć logicznie powiązanych rozdziałów, tworzących spójną całość i pozwalających na kompleksowe ujęcie problematyki zastosowania sztucznej inteligencji w controllingu finansowym.

Rozdział pierwszy pełni funkcję wprowadzającą: definiuje podstawowe pojęcia i cele controllingu, przedstawia jego miejsce w strukturze organizacyjnej oraz omawia kluczowe funkcje i narzędzia wspierające procesy decyzyjne w przedsiębiorstwie. Dzięki temu stanowi on kontekst dla dalszych rozważań teoretycznych i empirycznych.

W rozdziale drugim zaprezentowano teoretyczne podstawy sztucznej inteligencji oraz jej rosnące znaczenie w obszarze finansów. Przedstawiono najważniejsze mechanizmy działania systemów AI, w tym metody uczenia maszynowego, modele przetwarzania języka naturalnego oraz wybrane techniki analityczne istotne z perspektywy zastosowań biznesowych. Rozdział ten porządkuje aparaturę pojęciową i wyjaśnia, w jaki sposób rozwiązania oparte na



AI mogą wspierać analizę danych finansowych, prognozowanie oraz automatyzację wybranych zadań.

Rozdział trzeci koncentruje się na obszarach controllingu finansowego, w których narzędzia sztucznej inteligencji są już wykorzystywane lub wchodzi w fazę dojrzałych pilotaży. Na podstawie przeglądu literatury i raportów branżowych omówiono typowe scenariusze zastosowań (m.in. planowanie i budżetowanie, prognozowanie przychodów i kosztów, analiza odchyleń, zarządzanie ryzykiem, controlling operacyjny i strategiczny), a także wskazano korzyści oraz ograniczenia towarzyszące tym wdrożeniom. Zestawienie to porządkuje dotychczasowy dorobek i identyfikuje luki badawcze, które uzasadniają podjęcie badań własnych.

Rozdział czwarty przedstawia metodykę badań empirycznych, przebieg procesu gromadzenia danych oraz wyniki analiz. Zastosowano podejście mieszane: badanie ilościowe w formie ankiety online skierowanej do pracowników działów finansowych i controllingu w Polsce oraz jakościowy wywiad półstrukturyzowany z praktykiem posiadającym doświadczenie we wdrożeniach rozwiązań AI. Część ankietowa pozwoliła ocenić poziom wiedzy o AI, zaufanie do tej technologii oraz postrzegane korzyści i ryzyka automatyzacji procesów controllingowych, natomiast wywiad pogłębił wnioski i dostarczył kontekstu interpretacyjnego. Integracja wyników w ujęciu triangulacyjnym umożliwiła uchwycenie zarówno zbieżności, jak i rozbieżności między perspektywą ilościową i jakościową.

Rozdział piąty zawiera syntetyczne podsumowanie przeprowadzonych analiz, wnioski wynikające z części teoretycznej i empirycznej oraz rekomendacje praktyczne dotyczące wdrażania sztucznej inteligencji w procesach controllingowych. Wskazano zalecenia organizacyjne, kompetencyjne i technologiczne, podkreślając znaczenie ładu danych, mechanizmów nadzoru i wyjaśnialności modeli oraz zarządzania zmianą. Rozdział kończy omówienie ograniczeń badania i propozycje kierunków dalszych prac, w tym pogłębionych analiz sektorowych oraz badań porównawczych w różnych typach organizacji.

W niniejszej pracy zastosowano podejście mieszane, łączące analizę teoretyczną i dwa uzupełniające się komponenty empiryczne. Część teoretyczna obejmuje przegląd literatury naukowej oraz raportów branżowych uznanych instytucji, co pozwoliło zrekonstruować aktualny stan wiedzy na temat zastosowań sztucznej inteligencji w controllingu finansowym, identyfikując główne obszary zastosowań, spodziewane efekty biznesowe oraz kluczowe wyzwania wdrożeniowe. Wykaz źródeł wykorzystanych w tym przeglądzie został ujęty w bibliografii pracy.



Część ilościowa została zrealizowana w formie ankiety online skierowanej do pracowników działów finansowych i controllingowych w przedsiębiorstwach działających w Polsce. Kwestionariusz zawierał przede wszystkim pytania zamknięte, w tym elementy skal porządkowych i skal typu Likerta, zaprojektowane pod kątem pomiaru trzech obszarów: poziomu wiedzy o rozwiązaniach AI wykorzystywanych w controllingu, poziomu zaufania do tej technologii oraz percepcji korzyści i ryzyk związanych z automatyzacją zadań controllingowych. Dystrybucja ankiety miała charakter nielosowy i odbywała się za pośrednictwem sieci zawodowych oraz kontaktów branżowych. Do analizy włączono kompletne i spójne logicznie kwestionariusze. Dane poddano analizie z wykorzystaniem statystyki opisowej (miary tendencji centralnej i dyspersji), a w celu wstępnej oceny współwystępowania kluczowych zmiennych obliczono proste współczynniki korelacji. Tam, gdzie było to zasadne, zweryfikowano wewnętrzną spójność skonstruowanych skal (np. za pomocą współczynnika alfa Cronbacha), co zwiększa wiarygodność wniosków formułowanych na podstawie uzyskanych pomiarów.

Część jakościowa polegała na przeprowadzeniu półstrukturyzowanego wywiadu pogłębionego z ekspertem-praktykiem z obszaru finansów i controllingu, posiadającym doświadczenie w implementacji lub użytkowaniu rozwiązań opartych na sztucznej inteligencji. Respondenta dobrano celowo, kierując się kryteriami obejmującymi wieloletnią praktykę zawodową, styczność z narzędziami AI/ML oraz znajomość procesów controllingowych. Wywiad został przeprowadzony według scenariusza porządkującego rozmowę wokół kluczowych bloków tematycznych, takich jak: obszary zastosowań AI w controllingu, bariery organizacyjne i technologiczne, gotowość kompetencyjna zespołów, ryzyka i zagadnienia etyczno-prawne (w tym kwestie wyjaśnialności i kontroli modeli) oraz dobre praktyki wdrożeniowe. Za zgodą rozmówcy wywiad został zarejestrowany i poddany transkrypcji, a następnie przeanalizowany metodą analizy tematycznej. Zidentyfikowane kody i kategorie posłużyły do interpretacji wzorców ujawnionych w danych ankietowych oraz do sformułowania uzupełniających wyjaśnień.

Wyniki obu komponentów badawczych zintegrowano na etapie interpretacji, stosując podejście triangulacyjne. Dzięki temu możliwe było zestawienie obserwacji ilościowych z jakościowymi wnioskami eksperckimi, co ułatwiło uchwycenie zarówno zbieżności, jak i ewentualnych rozbieżności w ocenie roli i skutków wykorzystania AI w procesach controllingowych. Taka konstrukcja badania zwiększa trafność wnioskowania i pozwala przedstawić rekomendacje o większej użyteczności praktycznej.



Całość prac badawczych została przeprowadzona z poszanowaniem standardów etycznych. Udział w ankiecie był dobrowolny i anonimowy, a respondenci zostali poinformowani o celu badania i sposobie wykorzystania wyników. W przypadku wywiadu zapewniono poufność danych identyfikacyjnych oraz uzyskano zgodę na udział i rejestrację rozmowy. Dane zostały przetworzone i zarchiwizowane w sposób gwarantujący bezpieczeństwo informacji. Na końcu rozdziału omówiono ograniczenia badania, wynikające m.in. z nielosowego doboru próby oraz samo opisowego charakteru odpowiedzi, a także z jednostkowego charakteru wywiadu eksperckiego. Ograniczenia te uwzględniono przy formułowaniu wniosków i rekomendacji przedstawionych w rozdziale piątym.



# ROZDZIAŁ 1. WPROWADZENIE DO CONTROLLINGU FINANSOWEGO

## 1.1. Pojęcie controllingu i jego ewolucja – definicje, geneza oraz rozwój koncepcji controllingu

W literaturze controlling jest przedstawiany jako koncepcja zarządzania, której celem nie jest samo „liczenie”, ale wspieranie kierownictwa w podejmowaniu decyzji na podstawie uporządkowanych informacji. Jedno z częściej przywoływanych, syntetycznych ujęć wskazuje, że controlling to podsystem zarządzania odpowiadający za koordynację planowania i kontroli oraz dostarczanie menedżerom informacji potrzebnych do podejmowania racjonalnych decyzji – zarówno operacyjnych, jak i strategicznych. (Bielawski, 2025) W takim rozumieniu controlling łączy elementy informacyjne (dane, raporty, analizy) z elementami sterowania (planowanie, kontrola, korygowanie działań).

Istotną cechą controllingu jest jego orientacja na przyszłość. O ile klasyczna kontrola często kojarzy się ze sprawdzaniem wyników „po fakcie”, o tyle controlling ma wspierać także działania wyprzedzające – poprzez prognozowanie, wczesne ostrzeżenie i przygotowywanie rekomendacji. (Bielawski, 2025) W praktyce oznacza to, że controlling nie ogranicza się do rejestrowania i prezentowania wyników, ale pomaga zrozumieć, *dlaczego* wyniki są takie, jakie są, oraz *co można zrobić*, aby zwiększyć szanse realizacji celów.

Genezy controllingu zwykle upatruje się w rozwoju dużych organizacji oraz rosnącej złożoności zarządzania na przełomie XIX i XX wieku. Rozwój przemysłu, wzrost skali działania przedsiębiorstw oraz potrzeba lepszej koordynacji i kontroli kosztów sprawiły, że zaczęto poszukiwać narzędzi, które usprawnią procesy decyzyjne. Wskazuje się, że pierwsze wyspecjalizowane komórki controllingu pojawiały się w Stanach Zjednoczonych m.in. w przedsiębiorstwach sektora kolejowego, a także w dużych koncernach (jak General Electric), gdzie miały wspierać usprawnianie decyzji operacyjnych i strategicznych. (Bielawski, 2025) To „organizacyjne” źródło controllingu jest ważne, bo pokazuje, że koncepcja rozwijała się jako odpowiedź na realne problemy zarządcze – zwłaszcza w firmach, w których sama księgowość finansowa przestawała wystarczać do bieżącego sterowania działalnością.

W kolejnych dekadach controlling rozwijał się równolegle w różnych tradycjach. Z jednej strony wzmacniał się jego związek z rachunkowością zarządczą i analizą kosztów, z drugiej – coraz wyraźniej podkreślano rolę controllingu jako elementu systemu zarządzania, integrującego cele, plany, budżety i kontrolę ich realizacji. Wzrost zainteresowania controllingiem wiązano z istotnymi zmianami w warunkach prowadzenia działalności



gospodarczej, szczególnie widocznymi na początku XX wieku. (Krakowska i Bagieńska, 2025) Z czasem controlling zaczął być postrzegany jako narzędzie wspierające nie tylko kontrolę zasobów i kosztów, ale również decyzje zarządu oraz optymalizację wykorzystania zasobów w skali całego przedsiębiorstwa. (Krakowska i Bagieńska, 2025)

Ewolucję controllingu można ująć jako przejście od funkcji bardziej „sprawozdawczej” do roli silniej doradczej. W nowszych ujęciach podkreśla się, że controlling rozwijał wiele definicji, a jego współczesne rozumienie coraz częściej akcentuje koordynację procesów zarządczych i odpowiedzialność za jakość informacji dla menedżerów. (Bielawski, 2025) W praktyce rośnie znaczenie takich obszarów jak planowanie, budżetowanie, analiza odchyleń czy prognozowanie – czyli działań, które bezpośrednio wspierają zarządzanie i pozwalają szybciej reagować na zmiany.

Ważnym etapem rozwoju była także zmiana sposobu wykorzystania danych. Wskazuje się, że controlling przeszedł transformację od „mechanicznego” przetwarzania danych w kierunku ich bardziej twórczego wykorzystania, a controlling finansowy wykształcił się na styku rachunkowości, ekonomii i analizy kosztów. (Krakowska i Bagieńska, 2025) W praktyce oznaczało to stopniowe przesuwanie akcentu: od ewidencji i raportowania w kierunku analizy, interpretacji i rekomendacji dla decydentów. Dziś ten kierunek jest dodatkowo wzmacniany przez cyfryzację i rozwój narzędzi analitycznych, które przyspieszają raportowanie i poszerzają możliwości prognozowania. (Bielawski, 2025)

Podsumowując, controlling można traktować jako koncepcję, która powstała z potrzeby lepszego zarządzania w warunkach rosnącej skali i złożoności działania przedsiębiorstw. Z czasem ewoluował od funkcji głównie informacyjno-kontrolnej w stronę roli partnera zarządczego, wspierającego planowanie, koordynację, ocenę wyników i decyzje strategiczne. Ta ewolucja stanowi punkt wyjścia do dalszych rozważań o controllingu finansowym oraz o tym, w jaki sposób nowe technologie – w tym sztuczna inteligencja – mogą zmieniać jego narzędzia i zakres działania.

## **1.2 Rola controllingu finansowego w przedsiębiorstwie – miejsce w strukturze organizacyjnej oraz znaczenie dla podejmowania decyzji**

Controlling finansowy można traktować jako element systemu zarządzania, który łączy planowanie, kontrolę i analizę wyników z bieżącym wsparciem informacyjnym kadry kierowniczej. Jego sens nie polega wyłącznie na „liczeniu” i raportowaniu, ale na koordynowaniu procesów planowania i kontroli oraz dostarczaniu menedżerom informacji potrzebnych do podejmowania racjonalnych decyzji – zarówno operacyjnych, jak



i strategicznych. (Bielawski, 2025) W praktyce controlling finansowy tworzy więc „pomost” pomiędzy danymi finansowymi a decyzjami zarządczymi: porządkuje dane, interpretuje je i przekłada na wnioski istotne dla prowadzenia firmy.

W strukturze organizacyjnej przedsiębiorstwa controlling finansowy najczęściej lokuje się w pionie finansowym, blisko obszarów odpowiadających za sprawozdawczość, budżetowanie oraz analizę wyników. Z perspektywy roli w organizacji ważne jest to, że controlling nie działa „obok” zarządzania – przeciwnie, jest z nim ściśle powiązany poprzez stałą współpracę z menedżerami różnych działów. W literaturze podkreśla się, że controlling finansowy dzięki zbieraniu i analizie danych dotyczących przedsiębiorstwa oraz jego otoczenia zapewnia dokładniejsze informacje o sytuacji finansowej organizacji, a przez to wspiera realizację celów finansowych (np. poprzez planowanie, analizę kosztów, budżetowanie czy kontrolę wykonania). (Krakowska i Bagieńska, 2025) W efekcie rośnie jego znaczenie: controlling coraz częściej ma wymiar strategiczny, a nie jedynie techniczny. (Krakowska i Bagieńska, 2025)

Miejsce controllingu w strukturze zależy przy tym od wielkości i złożoności organizacji. W mniejszych firmach funkcja controllingu bywa realizowana przez jedną osobę (np. kontrolera finansowego), który samodzielnie przygotowuje analizy, raporty i rekomendacje dla właściciela lub zarządu. W większych przedsiębiorstwach controlling częściej przyjmuje formę wyodrębnionego zespołu lub działu, a rola kontrolera może mieć charakter kierowniczy – obejmujący zarządzanie procesem budżetowania, koordynację raportowania zarządczego oraz współpracę z innymi jednostkami organizacyjnymi. (Krakowska i Bagieńska, 2025) Taka lokalizacja w strukturze ułatwia też pełnienie roli „partnera biznesowego” – osoby, która nie tylko dostarcza dane, ale aktywnie uczestniczy w dyskusjach o kierunkach rozwoju, ryzykach i opłacalności działań.

Znaczenie controllingu finansowego dla podejmowania decyzji wynika głównie z tego, że decyzje menedżerskie wymagają nie tylko danych historycznych, ale również spojrzenia przyszłościowego. W ujęciu podkreślanym w literaturze controlling, oprócz klasycznego sprzężenia zwrotnego (analiza tego, co już się wydarzyło), powinien wykorzystywać także podejście wyprzedzające (feed forward), czyli wspierać planowanie, prognozowanie i wcześniejsze identyfikowanie odchyleń oraz ryzyk. (Bielawski, 2025) Oznacza to, że controlling finansowy wzmacnia proces decyzyjny m.in. przez: wczesne ostrzeżenie o niekorzystnych trendach, analizę przyczyn odchyleń, ocenę opłacalności działań i wariantów (np. scenariuszy kosztowych), a także przez dostarczanie spójnych informacji do ustalania priorytetów.



Warto też zauważyć, że rola controllingu – a razem z nią oczekiwania wobec kontrolerów – zmienia się wraz z otoczeniem gospodarczym i technologicznym. Wskazuje się m.in. na megatrendy (cyfrowa transformacja, rosnąca zmienność i niepewność), które zwiększają zapotrzebowanie na specjalistów w obszarze controllingu, określanych coraz częściej jako „biznespartnerzy”, menedżerowie informacji czy analitycy biznesowi. (Sadowska i Waśniewski, 2020) To pokazuje, że controlling finansowy jest dziś postrzegany nie tylko jako funkcja kontrolna, ale jako realne wsparcie w zarządzaniu – szczególnie tam, gdzie decyzje muszą być podejmowane szybko, na podstawie dużej liczby danych i przy ograniczonej pewności co do przyszłości.

### **1.3 Kluczowe funkcje i zadania controllingu – budżetowanie, planowanie, kontrola kosztów, analiza odchyleń i raportowanie**

W praktyce przedsiębiorstw controlling (w tym controlling finansowy) jest kojarzony przede wszystkim z zestawem powtarzalnych działań, które mają zapewnić menedżerom „czytelny obraz” sytuacji firmy oraz wesprzeć ich w podejmowaniu decyzji. W ujęciu systemowym controlling koordynuje procesy planowania i kontroli, a jednocześnie dostarcza informacji niezbędnych do decyzji operacyjnych i strategicznych. (Bielawski, 2025) Z tego powodu kluczowe zadania controllingu można uporządkować wokół pięciu obszarów: planowania, budżetowania, kontroli kosztów, analizy odchyleń oraz raportowania.

Planowanie jest punktem wyjścia dla pozostałych funkcji controllingu. Obejmuje zarówno plany krótkookresowe (operacyjne), jak i długookresowe (strategiczne), które wyznaczają cele finansowe i niefinansowe przedsiębiorstwa. W literaturze podkreśla się, że controlling powinien wykorzystywać przeszłość do planowania przyszłości, a jego istotną cechą jest orientacja na przyszłość (sprzężenie wyprzedzające – feed forward), a nie wyłącznie analiza wyników po fakcie. (Bielawski, 2025) W praktyce planowanie oznacza m.in. ustalanie celów sprzedażowych, kosztowych i inwestycyjnych, określanie zasobów potrzebnych do ich realizacji oraz budowanie wariantów działań (scenariuszy) na wypadek zmian w otoczeniu.

Z planowaniem bezpośrednio łączy się budżetowanie, które jest jedną z najbardziej rozpoznawalnych funkcji controllingu. Budżet można traktować jako „liczbowy zapis planu”, pozwalający przełożyć cele na konkretne wartości (np. przychody, koszty, wynik, przepływy pieniężne) i przypisać odpowiedzialność za ich realizację. W opracowaniach dotyczących roli komórki controllingu wskazuje się, że do jej podstawowych zadań należy opracowywanie planów operacyjnych i strategicznych oraz budżetowanie kosztów, przychodów i wyników w krótkich okresach czasu. (Sierpińska-Sawicz, 2015) W firmach większych budżetowanie ma



zwykle charakter cykliczny (np. roczny z podziałem na miesiące/kwartaly) i jest powiązane z systemem raportowania zarządczego oraz oceną realizacji celów.

Kolejnym obszarem jest kontrola kosztów, rozumiana szerzej niż sama ewidencja księgową. Controlling kosztów koncentruje się na identyfikowaniu czynników kosztotwórczych, analizie struktury kosztów oraz ocenie, na ile koszty są zgodne z przyjętymi założeniami i czy wspierają realizację celów. W praktyce przedsiębiorstw controlling finansowy obejmuje m.in. analizę kosztów i budżetowanie oraz kontrolę realizacji celów finansowych. (Krakowska i Bagińska, 2025) W zależności od organizacji controllingu kontrola kosztów może być prowadzona w układzie centrów odpowiedzialności (np. działy, projekty, linie produktowe), co ułatwia ocenę, gdzie powstają odchylenia i kto może realnie wpływać na ich ograniczenie.

Naturalnym „łącznikiem” między budżetowaniem a kontrolą kosztów jest analiza odchyleń. Jej celem jest porównanie wartości planowanych (budżetowych) z wykonaniem oraz ustalenie przyczyn różnic. W literaturze wskazuje się, że controlling monitoruje odchylenia od budżetów i planów oraz wyjaśnia przyczyny tych odchyleń, co ma bezpośrednie znaczenie dla możliwości korygowania działań w kolejnych okresach. (Sierpińska-Sawicz, 2015) Analiza odchyleń ma więc nie tylko charakter sprawozdawczy, ale przede wszystkim zarządczy: pozwala wychwycić problemy (np. wzrost kosztów surowców, spadek marży, opóźnienia w realizacji sprzedaży) i podjąć decyzje korygujące, zanim odchylenia „utrwalą się” w wynikach.

Ostatnim kluczowym elementem jest raportowanie, czyli przygotowywanie zestawień i informacji dla zarządu oraz menedżerów. Raportowanie w controllingu nie powinno ograniczać się do prezentowania wyników, ale ma wspierać interpretację danych, ocenę realizacji celów oraz podejmowanie decyzji. W ujęciu praktycznym raporty controllingowe często obejmują wynik i jego strukturę, koszty w przekrojach odpowiedzialności, analizę odchyleń, kluczowe wskaźniki (KPI), a także komentarz i rekomendacje. Podkreśla się przy tym, że controlling – przez koordynację planowania i kontroli oraz dostarczanie informacji – stanowi istotne narzędzie wspierające procesy zarządcze i decyzyjne. (Bielawski, 2025)

Podsumowując, budżetowanie, planowanie, kontrola kosztów, analiza odchyleń i raportowanie tworzą spójny „cykl controllingu”. Jego sens polega na tym, że plan (cele) zostaje przetłumaczony na budżet, następnie wyniki są monitorowane, analizowane pod kątem odchyleń, a wnioski trafiają do menedżerów w formie raportów wspierających decyzje. Dzięki temu controlling nie jest jedynie narzędziem rozliczania przeszłości, ale realnym wsparciem zarządzania – szczególnie w warunkach zmienności i rosnącej presji na szybkie reagowanie.



## 1.4 Narzędzia i metody controllingu finansowego – podstawowe techniki, modele analityczne oraz systemy informatyczne wspierające controlling

W praktyce controlling finansowy opiera się na zestawie narzędzi, które mają jeden wspólny cel: zamienić dane (często rozproszone) w użyteczną informację zarządczą, a następnie wesprzeć planowanie, kontrolę i podejmowanie decyzji. W literaturze podkreśla się, że controlling jest jednocześnie koncepcją zarządzania i „skrzynką narzędziową”, w której dobór metod zależy od potrzeb firmy, jej wielkości oraz rodzaju działalności. (Manuylenko i Shebzukhova, 2021) W związku z tym narzędzia controllingu można omówić w trzech grupach: (1) techniki planistyczno-kontrolne, (2) modele analityczne i metody oceny ryzyka, (3) systemy informatyczne wspierające zbieranie danych i raportowanie.

Pierwszą grupę stanowią techniki planistyczno-kontrolne, czyli narzędzia, które porządkują procesy zarządcze. Najbardziej klasycznym rozwiązaniem pozostaje budżetowanie (budżety kosztów, przychodów, wyniku, a często także przepływów pieniężnych), które pozwala przełożyć cele na liczby, przypisać odpowiedzialność oraz monitorować realizację planów. (Sierpińska-Sawicz, 2015) Współcześnie budżetowanie jest często wzmocnione o podejście wariantowe (np. scenariusze „optymistyczny–realny–pesymistyczny”), aby szybciej reagować na zmiany w otoczeniu. Z punktu widzenia controllingu ważna jest też analiza odchyleń oraz mechanizmy „wczesnego ostrzegania”, bo pozwalają nie tylko wykryć różnicę między planem a wykonaniem, ale także zidentyfikować jej przyczyny i przygotować działania korygujące. (Sierpińska-Sawicz, 2015)

Drugą grupę tworzą modele analityczne, które pomagają interpretować wyniki oraz przewidywać konsekwencje decyzji. W praktyce controllingu finansowego wykorzystuje się m.in. analizę wskaźnikową i porównawczą, analizy kosztów, a także metody „menedżerskie”, które porządkują spojrzenie na firmę i jej otoczenie. W literaturze wskazuje się na szerokie użycie takich narzędzi jak m.in. SWOT, PEST, analiza progu rentowności (CVP), analiza ABC/XYZ, benchmarking czy metody portfelowe (np. macierz BCG) – przy czym ich zastosowanie zależy od tego, czy controlling ma charakter bardziej strategiczny czy operacyjny. (Manuylenko i Shebzukhova, 2021) Takie narzędzia pozwalają lepiej zrozumieć, skąd biorą się wyniki, jakie czynniki je napędzają i gdzie są największe „dźwignie” poprawy (np. marża, koszt jednostkowy, wolumen sprzedaży).

W ramach modeli analitycznych coraz większe znaczenie ma też zarządzanie ryzykiem, zwłaszcza w przedsiębiorstwach narażonych na wahania kursów walut, stóp procentowych czy cen surowców. Zwraca się uwagę, że controlling – jako system ukierunkowany na przyszłość i wczesne ostrzeganie – naturalnie łączy się z pomiarem ryzyka i dostarczaniem informacji



o ekspozycji przedsiębiorstwa. (Kaszuba-Perz i Perz, 2008) W tym kontekście w praktyce (zwłaszcza w instytucjach finansowych, ale coraz częściej również w firmach niefinansowych) stosuje się miary typu Value at Risk (VaR) oraz jego modyfikacje (np. EaR, CFaR), które dają zarządowi prostą informację o skali potencjalnej straty w określonym horyzoncie czasu i przy przyjętym poziomie ufności. (Kaszuba-Perz i Perz, 2008) To nie jest narzędzie „dla każdego”, ale pokazuje kierunek: controlling coraz częściej łączy klasyczną kontrolę kosztów z elementami predykcji i kwantyfikacji ryzyka.

Trzecia grupa narzędzi to systemy informatyczne, bez których controlling w większych organizacjach jest dziś bardzo trudny do prowadzenia. W klasycznym ujęciu controlling bazuje na systemie informacji zarządczej, który obejmuje pozyskiwanie, przechowywanie, przetwarzanie i przekazywanie informacji menedżerom – zasilany danymi zarówno z wnętrza firmy, jak i z otoczenia. (Kaszuba-Perz i Perz, 2008) W praktyce oznacza to korzystanie z systemów takich jak ERP/księgowość, CRM, moduły produkcyjne i sprzedażowe, a następnie integrację danych w spójne raporty.

Co istotne, mimo rozwoju wyspecjalizowanych narzędzi, wciąż bardzo często podstawowym narzędziem controllera jest arkusz kalkulacyjny – wskazywany jako najczęściej stosowane rozwiązanie w praktyce, które dodatkowo w ostatnich latach mocno się rozwinęło i oferuje szerokie możliwości analityczne. (Sadowska i Waśniewski, 2020) Jednocześnie rośnie znaczenie narzędzi klasy Business Intelligence (BI), które integrują dane z różnych źródeł (np. ERP, CRM) i wykorzystują je do analiz, prognozowania oraz raportowania, ułatwiając przejście controllingu z roli „dostawcy danych” do roli partnera zarządzania. (Bielawski, 2025) Współczesne trendy rozwoju systemów wspierających controlling obejmują także rozwiązania chmurowe, nacisk na bezpieczeństwo danych, rozwój analityki w czasie rzeczywistym, Big Data, a także uproszczenie korzystania z narzędzi (np. język naturalny, wizualizacje, interaktywność). (Sadowska i Waśniewski, 2020)

Warto dodać, że w obszarze automatyzacji coraz częściej wskazuje się na rozwiązania typu RPA (Robotic Process Automation), szczególnie w controllingu finansowym, gdzie występuje wiele powtarzalnych czynności. RPA może przyspieszać zbieranie i konsolidację danych, ograniczać błędy oraz wspierać integrację z narzędziami BI. (Bielawski, 2025) Z perspektywy controllingu oznacza to realne odciążenie zadań rutynowych (np. cykliczne raporty, uzgodnienia danych), a przesunięcie pracy controllera bardziej w stronę analizy i rekomendacji.

Podsumowując, narzędzia controllingu finansowego obejmują zarówno klasyczne techniki (budżetowanie, analiza odchyleń, raportowanie), jak i szersze modele analityczne



(w tym pomiar ryzyka) oraz rosnący zestaw narzędzi IT (Excel, BI, automatyzacja, integracja danych). W kolejnych częściach pracy będzie to szczególnie istotne, ponieważ właśnie na tej bazie pojawia się przestrzeń dla rozwiązań opartych na sztucznej inteligencji, które mogą dalej usprawniać analizę i raportowanie.

### **1.5 Wyzwania i kierunki rozwoju controllingu – rosnące znaczenie danych, cyfryzacja, nowe kompetencje controllerów**

Współczesny controlling (w tym controlling finansowy) rozwija się w warunkach rosnącej zmienności otoczenia i coraz większej dostępności danych. W praktyce oznacza to, że od controllingu oczekuje się nie tylko rozliczania wyników, lecz także szybkiego dostarczania informacji „na teraz” oraz przygotowywania analiz wyprzedzających (prognoz, symulacji, scenariuszy). W literaturze zwraca się uwagę, że cyfryzacja procesów zarządczych wymusza zmianę sposobu działania controllerów i przesuwa ich rolę w stronę partnera doradczego dla menedżerów. (Bielawski, 2025)

Jednym z kluczowych kierunków rozwoju jest rosnące znaczenie danych – nie tylko finansowych, ale również niefinansowych. Wskazuje się, że controlling coraz częściej działa w warunkach dużych zbiorów danych (Big Data), a przewagę zyskują organizacje, które potrafią te dane integrować i przekształcać w wnioski do decyzji. (Bielawski, 2025) Zwracano na to uwagę również w dyskusjach środowiska naukowego i praktyków – m.in. podczas konferencji poświęconej wyzwaniom współczesnej rachunkowości i controllingu, gdzie akcentowano potrzebę reagowania na zmiany oraz rozwijania metod pomiaru i raportowania w nowych warunkach funkcjonowania przedsiębiorstw. (Bednarek, 2023) W praktyce controlling staje się więc bardziej „data-driven”, a sprawne raportowanie i interpretacja danych mają bezpośredni wpływ na jakość decyzji zarządczych.

Drugi obszar zmian to cyfryzacja i informatyczne wsparcie controllingu. Wskazuje się, że obecna faza digitalizacji – oparta na zaawansowanej analityce, Big Data oraz rozwiązaniach AI/ML – ma charakter jakościowej zmiany, ponieważ automatyzuje część zadań, które wcześniej stanowiły trzon pracy controllera. (Bielawski, 2025) W praktyce oznacza to szersze wykorzystanie narzędzi klasy Business Intelligence, rozwiązań chmurowych, analityki w czasie rzeczywistym, a także automatyzacji (np. RPA). Podczas debaty branżowej podkreślano, że na rozwój narzędzi informatycznych wspierających controlling wpływają m.in. rozwój BI, „chmury”, nacisk na bezpieczeństwo danych, rozwój AI i uczenia maszynowego, rosnące znaczenie informacji niefinansowych, Big Data i analizy real-time, a także upraszczanie sposobu korzystania z narzędzi (np. język naturalny, wizualizacje,



interaktywność). (Sadowska i Waśniewski, 2020) Jednocześnie zwracano uwagę, że mimo rozwoju zaawansowanych systemów wciąż bardzo powszechnym narzędziem pozostaje arkusz kalkulacyjny, który również dynamicznie się rozwija i jest szeroko wykorzystywany w praktyce. (Sadowska i Waśniewski, 2020)

Cyfryzacja pociąga za sobą także wyzwania wdrożeniowe. W praktyce firm problemem bywa jakość i spójność danych, integracja źródeł (np. ERP, CRM, systemy sprzedaży) oraz utrzymanie standardów kontroli i bezpieczeństwa. Z perspektywy controllingu oznacza to konieczność budowania ładu informacyjnego: ustalania definicji wskaźników, odpowiedzialności za dane, zasad walidacji oraz sposobów raportowania. W dyskusjach naukowych i praktycznych podkreśla się również rolę systemów informatycznych w usprawnianiu procesów budżetowania (zarówno na etapie projektowania, jak i realizacji i rozliczania), co pokazuje, że rozwój controllingu jest coraz mocniej powiązany z rozwojem narzędzi IT. (Dyczkowski, 2024)

Trzeci, bardzo istotny kierunek rozwoju to zmiana profilu kompetencyjnego controllerów. W literaturze wskazuje się, że rola tradycyjnego controllera, skoncentrowana na danych historycznych i analizach retrospektywnych, przekształca się w rolę bardziej proaktywną, nastawioną na prognozowanie oraz wspieranie decyzji w czasie rzeczywistym. (Bielawski, 2025) Wraz z tym rośnie znaczenie kompetencji cyfrowych i analitycznych: pracy z danymi, rozumienia narzędzi BI, podstaw statystyki i wizualizacji, a także ogólnej znajomości zasad działania AI. Wprost podkreśla się, że kompetencje technologiczne stają się komplementarne wobec wiedzy finansowej, a rynek oczekuje specjalistów łączących perspektywę biznesową i technologiczną. (Bielawski, 2025)

Warto też zauważyć, że zmiana dotyczy nie tylko „twardych” umiejętności. Pod wpływem megatrendów (cyfrowa transformacja, globalizacja, rosnąca zmienność i niepewność, ukierunkowanie na tworzenie wartości oraz cele społeczne i ekologiczne) wzrasta zapotrzebowanie na controllerów pełniących rolę biznespartnerów, menedżerów informacji czy analityków biznesowych. (Sadowska i Waśniewski, 2020) Taki kierunek rozwoju powoduje, że controller powinien rozwijać również kompetencje komunikacyjne (tłumaczenie wyników na język biznesu), umiejętność współpracy międzydziałowej, a także zdolność do krytycznej oceny wyników analiz generowanych przez narzędzia informatyczne.

Podsumowując, kluczowe wyzwania i kierunki rozwoju controllingu dotyczą: (1) pracy w środowisku rosnącej ilości danych, (2) postępującej cyfryzacji i automatyzacji procesów, (3) zmiany roli i kompetencji controllerów w stronę analityczno-doradczą. W kolejnych rozdziałach będzie to ważne tło dla rozważań o sztucznej inteligencji, ponieważ AI może



przyspieszać część procesów controllingowych, ale jednocześnie zwiększa wymagania wobec jakości danych, nadzoru nad analizą i kompetencji użytkowników.



## ROZDZIAŁ 2. TEORETYCZNE PODSTAWY SZTUCZNEJ INTELIGENCJI I JEJ ZASTOSOWANIA W FINANSACH

### 2.1 Definicja i krótka historia sztucznej inteligencji – zarys pojęcia AI, najważniejsze etapy rozwoju

Sztuczna inteligencja (AI, *artificial intelligence*) jest pojęciem, które weszło do języka biznesu, nauki i mediów, jednak w literaturze podkreśla się, że trudno wskazać jedną „ostateczną” definicję. Wynika to z faktu, że AI obejmuje wiele metod i podejść, a granica między „zwykłym” oprogramowaniem a systemami inteligentnymi nie zawsze jest oczywista. W ujęciu praktycznym AI najczęściej opisuje się przez zdolności systemu: analizę danych, uczenie się na podstawie przykładów, rozpoznawanie wzorców, wnioskowanie oraz wspieranie procesu decyzyjnego. (Rózanowski, 2007)

W literaturze spotyka się definicje akcentujące, że AI to dziedzina informatyki zajmująca się tworzeniem rozwiązań, które potrafią wykonywać zadania kojarzone tradycyjnie z inteligencją człowieka (np. rozumienie języka, klasyfikowanie, przewidywanie, podejmowanie decyzji). Jednocześnie zwraca się uwagę, że współczesne systemy AI nie muszą „myśleć jak człowiek” – wystarczy, że skutecznie realizują cel (np. trafnie prognozują, wykrywają anomalie, wspierają wybór decyzji). (Robaczyński, 2022) Takie podejście jest szczególnie ważne w finansach, gdzie liczy się skuteczność i wiarygodność modelu, a nie to, czy sposób działania „przypomina” ludzki tok myślenia.

Jeżeli chodzi o krótki rys historyczny, początków AI zwykle szuka się w połowie XX wieku. W literaturze wskazuje się, że sam termin „sztuczna inteligencja” pojawił się w środowisku naukowym w latach 50., a rozwój tej dziedziny początkowo opierał się głównie na podejściu symbolicznym (regułowym). Oznaczało to budowanie programów, które miały rozwiązywać problemy na podstawie zestawu reguł i logiki, np. poprzez określone schematy wnioskowania. (Stylec-Szromek, 2018) Ten etap pozwolił stworzyć pierwsze systemy rozwiązujące zadania logiczne, jednak wraz ze wzrostem złożoności problemów okazało się, że ręczne „wpisywanie” wiedzy w reguły jest trudne, kosztowne i mało elastyczne.

W kolejnych dekadach rozwijały się m.in. systemy ekspertowe, czyli rozwiązania oparte na bazie wiedzy i mechanizmach wnioskowania, które miały wspierać decyzje specjalistów w wąskich dziedzinach. Ten kierunek przyniósł praktyczne wdrożenia, ale równocześnie ujawnił ograniczenia: systemy były trudne w utrzymaniu, wymagały stałej aktualizacji reguł i często nie radziły sobie w warunkach zmiany otoczenia lub niepełnych danych. W literaturze zwraca się uwagę, że rozwój AI przebiegał falami: okresy intensywnego zainteresowania i wysokich



oczekiwań przeplatały się z etapami spadku finansowania i rozczarowania efektami (tzw. „zimy AI”). (Aghion, Jones i Jones, 2017)

Przełomem dla współczesnego zastosowania AI okazał się wzrost znaczenia podejść opartych na danych, czyli uczenia maszynowego. W tym podejściu system nie otrzymuje od człowieka kompletnego zestawu reguł, tylko „uczy się” na danych, szukając zależności i wzorców, które później wykorzystuje do klasyfikacji, prognozowania lub wykrywania nieprawidłowości. W praktyce biznesowej rozwój uczenia maszynowego został mocno przyspieszony przez dwa czynniki: (1) gwałtowny wzrost dostępności danych oraz (2) większą moc obliczeniową i rozwój infrastruktury informatycznej. W konsekwencji AI zaczęła coraz częściej wspierać zadania, które wcześniej były wykonywane ręcznie lub wymagały długotrwałych analiz (np. segmentacja klientów, ocena ryzyka, prognozy sprzedaży i kosztów, wykrywanie nadużyć).

Warto podkreślić, że rozwój AI jest istotny nie tylko z technologicznego, ale również z ekonomicznego punktu widzenia. W literaturze ekonomicznej AI bywa przedstawiana jako technologia ogólnego zastosowania, która może wpływać na produktywność i tempo wzrostu gospodarczego, a także na strukturę rynku pracy i relacje między kapitałem a pracą. To podejście jest szczególnie przydatne w kontekście finansów i controllingu, ponieważ pokazuje, że AI nie jest „modą”, ale elementem szerszych przemian: organizacje, które potrafią wykorzystać dane i narzędzia analityczne, zyskują przewagę w szybkości reakcji, jakości prognoz i efektywności procesów.

Podsumowując, sztuczna inteligencja przeszła drogę od systemów regułowych i prób formalizacji „rozumowania”, przez systemy ekspertowe, aż do dominacji podejść opartych na danych, w których kluczową rolę odgrywa uczenie maszynowe. Z perspektywy dalszych rozdziałów tej pracy najważniejsze jest pragmatyczne ujęcie AI: jako zestawu narzędzi i metod, które pozwalają automatyzować część zadań analitycznych, przyspieszać przetwarzanie informacji i wspierać decyzje. Jednocześnie skuteczność AI zależy od jakości danych, właściwego doboru metod oraz kompetencji osób, które z tych narzędzi korzystają. (Różanowski, 2007)

W literaturze przedmiotu sztuczna inteligencja definiowana jest jako zbiór metod i technologii umożliwiających systemom informatycznym wykonywanie zadań wymagających dotychczas ludzkiej inteligencji. Russell i Norvig wskazują, że AI obejmuje systemy postrzegające otoczenie, przetwarzające informacje oraz podejmujące działania w sposób maksymalizujący osiągnięcie określonych celów. (Russell i Norvig, 2021) Współczesne



podejście do AI coraz częściej koncentruje się na zdolności systemów do uczenia się na podstawie danych oraz adaptacji do zmieniających się warunków.

Jordan i Mitchell podkreślają, że rozwój AI w ostatnich latach związany jest przede wszystkim z postępem w obszarze uczenia maszynowego oraz dostępnością dużych zbiorów danych. (Jordan i Mitchell, 2015) W ujęciu ekonomicznym Agrawal, Gans i Goldfarb zwracają uwagę, że AI redukuje koszt predykcji, co ma istotne konsekwencje dla procesów decyzyjnych w organizacjach. (Agrawal, Gans i Goldfarb, 2018)

## **2.2 Główne koncepcje i rodzaje AI – uczenie maszynowe, uczenie głębokie i robotyzacja procesów**

W praktyce biznesowej (także w finansach i controllingu) termin „sztuczna inteligencja” bywa używany bardzo szeroko. Żeby uporządkować pojęcia, warto przyjąć prosty podział: AI jako ogólna „rodzina metod”, a w jej ramach konkretne podejścia, takie jak uczenie maszynowe (machine learning), uczenie głębokie (deep learning) oraz robotyzacja procesów (RPA). Takie rozróżnienie jest przydatne, bo te rozwiązania różnią się sposobem działania i tym, do jakich zadań są najbardziej praktyczne. (Krajewska, 2024)

Uczenie maszynowe (ML) można opisać jako podejście, w którym system nie działa wyłącznie według sztywno zapisanych reguł, lecz „uczy się” na danych. W praktyce oznacza to, że algorytm analizuje przykłady (np. dane historyczne) i na tej podstawie tworzy model, który później potrafi: klasyfikować (np. rozpoznawać typy transakcji), przewidywać (np. prognozować przychody lub koszty) albo wykrywać nieprawidłowości (np. anomalie w danych). (Krajewska, 2024) Z punktu widzenia controllingu ważne jest to, że ML dobrze sprawdza się w sytuacji, gdy firma ma dużo danych, a relacje między zmiennymi są zbyt złożone, by opisać je prostą regułą „jeśli... to...”.

W ramach ML spotyka się różne sposoby uczenia, ale na potrzeby tej pracy wystarczy intuicyjne rozróżnienie:

- uczenie nadzorowane (model uczy się na danych z „prawidłową odpowiedzią”, np. historyczne wyniki i ich przyczyny),
- uczenie nienadzorowane (model sam szuka struktur i wzorców w danych, np. segmentuje koszty lub klientów),
- uczenie ze wzmocnieniem (model uczy się przez „nagrody i kary”, częściej spotykane np. w optymalizacji działań). (Ghai, Rawal, Dhir i Tripathi, 2024)



W praktyce controllingowej najczęściej spotyka się dwa pierwsze podejścia, bo odpowiadają na typowe potrzeby: prognozowanie, klasyfikację i analizę wzorców w danych.

Uczenie głębokie (DL) jest szczególnym rodzajem uczenia maszynowego, w którym wykorzystuje się wielowarstwowe sieci neuronowe. Nie wchodząc w techniczne szczegóły, można przyjąć, że DL jest szczególnie przydatne wtedy, gdy dane są „złożone” albo mniej ustrukturyzowane – np. tekst, obraz, dźwięk. W kontekście finansów może to mieć znaczenie np. przy automatycznej analizie dokumentów, ekstrakcji informacji z opisów transakcji czy pracy z językiem naturalnym (np. streszczanie raportów, analiza zapisów umów). Jednocześnie DL zwykle wymaga większych zbiorów danych i zasobów obliczeniowych niż klasyczne ML, dlatego jego wdrożenie bywa bardziej wymagające organizacyjnie. (Ghai, Rawal, Dhir i Tripathi, 2024)

Warto też dodać, że w literaturze często spotyka się podział na AI wąską (narrow AI) i AI ogólną (AGI). Narrow AI to rozwiązania wyspecjalizowane w konkretnych zadaniach (np. prognozowanie, rozpoznawanie twarzy, rekomendacje), natomiast AGI oznaczałaby system o „ogólnej” inteligencji porównywalnej do ludzkiej. W praktyce biznesowej niemal wszystkie wdrożenia dotyczą dziś AI wąskiej, co jest istotne, bo pomaga realistycznie oceniać możliwości technologii: system może być świetny w jednym zadaniu, ale nie zastępuje szerokiego myślenia człowieka. (Kondort i Cioc, 2024)

Osobnym, bardzo często spotykanym w firmach nurtem jest robotyzacja procesów (RPA – Robotic Process Automation). RPA bywa wrzucane do jednego worka z AI, ale w praktyce jest to narzędzie przede wszystkim do automatyzacji powtarzalnych czynności w systemach informatycznych (np. przepisywanie danych między systemami, generowanie raportów, pobieranie danych z kilku źródeł, tworzenie cyklicznych zestawień). Najważniejsza różnica jest taka, że klasyczne RPA nie „uczy się” jak ML – raczej odtwarza ustalone kroki procesu. Z perspektywy controllingu RPA ma duże znaczenie, bo automatyzuje część żmudnych działań (zbieranie danych, wstępne raporty), dzięki czemu controlling może przesuwać się w stronę analizy i interpretacji wyników. (Bielawski, 2025)

W praktyce organizacje coraz częściej łączą te podejścia. Przykładowo: RPA może pobierać dane z systemów, porządkować je i ładować do raportów, a model ML może na tych danych wykonywać prognozę lub wskazywać nietypowe odchylenia. Takie połączenie jest szczególnie atrakcyjne dla finansów i controllingu, ponieważ pozwala automatyzować „technikę” procesu, a jednocześnie podnosić jakość analiz. (Robaczyński, 2022)



Podsumowując, dla dalszych rozdziałów pracy kluczowe jest rozumienie, że: ML odpowiada głównie za analizę i predykcję na podstawie danych, DL wzmacnia ten obszar szczególnie w pracy z danymi złożonymi (np. tekst), a RPA automatyzuje powtarzalne czynności procesowe. Takie uporządkowanie pozwala później konkretnie wskazywać, *które elementy controllingu* mogą być wspierane przez AI i w jaki sposób.

Współczesne badania nad AI koncentrują się przede wszystkim na algorytmach uczenia nadzorowanego, nienadzorowanego oraz uczenia ze wzmocnieniem. Goodfellow, Bengio i Courville wskazują, że rozwój sieci neuronowych oraz deep learning znacząco zwiększył zdolność systemów do rozpoznawania wzorców w dużych zbiorach danych. (Goodfellow, Bengio i Courville, 2016) Z kolei Domingos opisuje pięć głównych nurtów uczenia maszynowego, wskazując na różnorodność podejść metodologicznych. (Domingos, 2015)

W kontekście zastosowań finansowych szczególne znaczenie mają modele predykcyjne, drzewa decyzyjne oraz algorytmy klasyfikacyjne wykorzystywane w ocenie ryzyka i prognozowaniu wyników finansowych. (Makridakis, Spiliotis i Assimakopoulos, 2018)

### **2.3 Zastosowania AI w finansach – główne obszary i przykłady wykorzystania**

Zastosowanie sztucznej inteligencji w finansach rozwija się przede wszystkim tam, gdzie organizacje pracują na dużych zbiorach danych i potrzebują szybkich analiz. (Cao L. , 2020) W literaturze podkreśla się, że AI jest wykorzystywana zarówno do zadań stricte analitycznych (np. prognozowania), jak i do automatyzacji procesów (np. przygotowania danych, wsparcia raportowania), a w ostatnim czasie także do pracy z tekstem i dokumentami (np. generowanie podsumowań). (Cao L. , 2020) W praktyce finansowej AI ma więc charakter narzędziowy: wspiera wybrane etapy pracy, a nie zastępuje całego procesu zarządzania finansami. (Cao L. , 2020)

Jednym z najbardziej rozpowszechnionych obszarów jest prognozowanie i analityka predykcyjna. Modele uczenia maszynowego są wykorzystywane do przewidywania wyników, kosztów, przychodów czy przepływów pieniężnych, a także do prognozowania wskaźników ryzyka i wczesnego ostrzegania o niekorzystnych trendach. (Cao L. , 2020) Wskazuje się, że przewaga metod AI polega na możliwości uwzględniania wielu czynników jednocześnie i wykrywaniu zależności, które w klasycznych analizach mogą pozostać niezauważone. (Cao L. , 2020) Jednocześnie jakość prognozy zależy bezpośrednio od jakości danych i sposobu przygotowania modelu – dlatego AI w prognozowaniu nie jest automatycznym „gwarantem” poprawy wyników, lecz wymaga dobrego wdrożenia i kontroli. (Cao, Jiang, Lei i Zhou, 2024)



Drugim ważnym zastosowaniem AI jest zarządzanie ryzykiem oraz wykrywanie nieprawidłowości. Dotyczy to m.in. wykrywania nadużyć i monitoringu transakcji (w instytucjach finansowych), ale również identyfikacji anomalii w danych księgowych i rozliczeniach (w przedsiębiorstwach niefinansowych). (Cao, Jiang, Lei i Zhou, 2024) W literaturze podkreśla się, że AI sprawdza się w tym obszarze ze względu na możliwość wykrywania wzorców i odstępstw na podstawie dużych wolumenów danych, co jest trudne do wykonania w pełni manualnie. (Cao, Jiang, Lei i Zhou, 2024) Z perspektywy controllingu ma to znaczenie, ponieważ narzędzia oparte na AI mogą wspierać kontrolę jakości danych, ograniczać ryzyko błędów oraz szybciej sygnalizować nietypowe odchylenia. (Eisfeldt i Schubert, 2024)

Kolejny obszar dotyczy decyzji kredytowych i oceny wiarygodności. AI wspiera scoring kredytowy, prognozowanie prawdopodobieństwa opóźnień w spłacie, segmentację klientów czy personalizację oferty. Wskazuje się przy tym, że obok potencjalnej poprawy trafności prognoz rośnie znaczenie wyjaśnialności modeli oraz zgodności z regulacjami, ponieważ decyzje finansowe tego typu są wrażliwe i wymagają przejrzystości. (Eisfeldt i Schubert, 2024)

W ostatnich latach szczególnie mocno wybrzmiewa także temat generatywnej AI (np. narzędzi opartych na dużych modelach językowych). Zwraca się uwagę, że rozwiązania tego typu mogą wspierać pracę finansową w obszarze tekstu i dokumentów: streszczać raporty, porządkować informacje z wielu źródeł, a także przygotowywać wstępne szkice komentarzy zarządczych. (Eisfeldt i Schubert, 2024) Jednocześnie podkreśla się, że generatywna AI może tworzyć treści brzmiące wiarygodnie, ale niezgodne z danymi, dlatego jej wykorzystanie wymaga procedur weryfikacji oraz jasnego określenia odpowiedzialności człowieka za końcową interpretację i decyzję. (Eisfeldt i Schubert, 2024)

Podsumowując, główne zastosowania AI w finansach obejmują prognozowanie i analitykę predykcijną, zarządzanie ryzykiem i wykrywanie anomalii, wsparcie decyzji kredytowych oraz coraz częściej pracę z tekstem i dokumentami w ramach generatywnej AI. Z perspektywy tej pracy jest to ważne tło, ponieważ część tych zastosowań można bezpośrednio przełożyć na zadania controllingu finansowego, takie jak prognozowanie, analiza odchyleń, raportowanie czy wczesne ostrzeżenie. (Cao L. , 2020)

Oprócz przeglądu praktycznych zastosowań AI w finansach, w literaturze naukowej prowadzone są badania empiryczne oceniające skuteczność modeli uczenia maszynowego w prognozowaniu i zarządzaniu ryzykiem. Makridakis i współautorzy wskazują, że metody uczenia maszynowego w wielu przypadkach osiągają wyższą trafność prognoz niż klasyczne



modele statystyczne, jednak wymagają odpowiedniej walidacji oraz kontroli jakości danych. (Makridakis, Spiliotis i Assimakopoulos, 2018)

W obszarze rachunkowości i analityki finansowej Appelbaum, Kogan i Vasarhelyi podkreślają, że wykorzystanie big data oraz narzędzi AI może znacząco zwiększać zakres analizowanych informacji oraz poprawiać jakość monitoringu procesów finansowych. (Appelbaum, Kogan i Vasarhelyi, 2017) Z kolei Sutton, Holt i Arnold wskazują, że rozwój AI zmienia charakter pracy specjalistów finansowych, przesuując akcent z przetwarzania danych na ich interpretację i ocenę ryzyka. (Sutton, Holt i Arnold, 2016)

Badania Begenau, Farboodi i Veldkamp pokazują natomiast, że dostęp do dużych zbiorów danych i zaawansowanych narzędzi analitycznych może wpływać na przewagę konkurencyjną przedsiębiorstw. (Begenau, Farboodi i Veldkamp, 2018) W kontekście finansów oznacza to, że skuteczne wykorzystanie AI może przekładać się nie tylko na usprawnienie procesów, ale także na strategiczne pozycjonowanie organizacji na rynku.

#### **2.4 Korzyści i ograniczenia wykorzystania AI w finansach – perspektywa praktyczna**

Wdrożenia sztucznej inteligencji w finansach są zwykle uzasadniane dążeniem do szybszego przetwarzania informacji i poprawy jakości analiz. W ujęciu praktycznym AI wspiera przede wszystkim te obszary, w których występuje duża liczba danych oraz powtarzalne schematy decyzyjne (np. prognozowanie, wykrywanie anomalii, ocena ryzyka). Zwraca się uwagę, że dzięki wykorzystaniu modeli uczących się na danych organizacje mogą sprawniej identyfikować trendy oraz reagować na nie w krótszym czasie niż w klasycznym podejściu opartym wyłącznie na analizie manualnej. (Cao L. , 2020)

Pierwszą, często wskazywaną korzyścią jest automatyzacja i oszczędność czasu. W finansach i rachunkowości rośnie znaczenie rozwiązań automatyzujących obieg dokumentów oraz powtarzalne czynności (np. OCR, RPA), co skraca czas potrzebny na przygotowanie danych i raportów. (Radziszowska i Sobolevska, 2024) W kontekście controllingu ma to duże znaczenie, ponieważ przesuwa ciężar pracy z „przygotowania zestawień” na interpretację wyników i wsparcie decydentów. (Radziszowska i Sobolevska, 2024) Równocześnie podkreśla się, że automatyzacja może pozytywnie wpływać na ograniczenie błędów powstających na etapie ręcznego przepisywania danych, choć nie eliminuje ryzyka błędów całkowicie – raczej zmienia ich charakter (z „ludzkich” na „systemowe”). (Nesterak, Jabłoński i Kowalski, 2020)

Drugą korzyścią jest wzmocnienie analityki predykcyjnej i wczesnego ostrzegania. W literaturze przeglądowej wskazuje się, że AI jest używana do prognozowania zjawisk



finansowych, analizy ryzyk oraz wykrywania anomalii, a jej przewaga ujawnia się szczególnie wtedy, gdy relacje między zmiennymi są złożone i trudno je opisać prostymi regułami. (Cao, Jiang, Lei i Zhou, 2024) Z perspektywy controllingu oznacza to potencjalnie lepsze prognozy (np. kosztów, przychodów, płynności) oraz szybsze wykrywanie nietypowych odchyleń wymagających wyjaśnienia. (Cao, Jiang, Lei i Zhou, 2024)

Równoległe literatura podkreśla rosnącą rolę AI w pracy z informacją jakościową, zwłaszcza w obszarze tekstu i dokumentów. W praktyce finansów coraz częściej wykorzystuje się narzędzia, które potrafią porządkować treści, streszczać materiały lub wspierać przygotowanie komentarzy zarządczych. Jednocześnie zauważa się, że tego typu rozwiązania wymagają ostrożności, ponieważ mogą generować treści brzmiące wiarygodnie, ale niepoparte danymi lub niespójne z dokumentacją źródłową. (Eisfeldt i Schubert, 2024)

Korzyściom towarzyszą jednak wyraźne ograniczenia i ryzyka wdrożeniowe. Po pierwsze, w finansach kluczowa jest jakość danych: jeśli dane są niekompletne, niespójne lub źle zdefiniowane, model może utrwalac błędne wnioski (zasada „garbage in, garbage out”). W badaniach podkreśla się również znaczenie przygotowania organizacyjnego: ładu informacyjnego, odpowiedzialności za dane i stałego monitorowania działania modeli. (Cao L., 2020) Z perspektywy controllingu jest to szczególnie ważne, bo controlling bazuje na porównywalności wskaźników i stabilnych definicjach miar (np. kosztów, marż, KPI), a brak spójności utrudnia interpretację wyników. (Nesterak, Jabłoński i Kowalski, 2020)

Po drugie, ograniczeniem są kwestie wyjaśnialności i kontroli. W finansach, gdzie decyzje często podlegają audytowi lub ocenie regulacyjnej, duże znaczenie ma możliwość uzasadnienia wyniku modelu (dlaczego algorytm zasugerował taki, a nie inny wniosek). Wskazuje się, że wraz ze wzrostem złożoności modeli rośnie ryzyko „czarnej skrzynki” oraz ryzyko błędów trudnych do szybkiego wychwycenia bez odpowiedniego nadzoru. (Eisfeldt i Schubert, 2024) Po trzecie, barierami mogą być koszty wdrożenia, integracja z istniejącymi systemami oraz niedobory kompetencji (zarówno technicznych, jak i interpretacyjnych) w zespołach finansowych. (Radziszowska i Sobolevska, 2024)

W literaturze coraz częściej podkreśla się również problem tzw. model risk, czyli ryzyka związanego z błędną konstrukcją lub niewłaściwym zastosowaniem modeli analitycznych. Bank Rozrachunków Międzynarodowych wskazuje, że instytucje finansowe powinny wdrażać formalne procedury walidacji modeli, dokumentowania ich założeń oraz monitorowania skuteczności w czasie. (Supervision, Basel Committee on Banking, 2018)

Istotnym zagadnieniem jest także problem uprzedzeń algorytmicznych (algorithmic bias). Barocas i Selbst wskazują, że modele uczące się na danych historycznych mogą utrwalac



istniejące nierówności lub niezamierzone schematy decyzyjne. (Barocas i Selbst, 2016) W kontekście finansów oznacza to konieczność szczególnej ostrożności przy wykorzystaniu AI w procesach oceny ryzyka czy klasyfikacji danych.

Doshi-Velez i Kim zwracają uwagę na rosnące znaczenie interpretowalności modeli, zwłaszcza w sektorach regulowanych. (Doshi-Velez i Kim, 2017) W finansach i controllingu możliwość wyjaśnienia wyniku modelu ma kluczowe znaczenie z perspektywy audytu, odpowiedzialności zarządczej oraz zgodności z regulacjami.

Podsumowując, AI w finansach daje realne korzyści w zakresie automatyzacji, analityki predykcyjnej oraz sprawniejszego przetwarzania informacji, ale jednocześnie wymaga uporządkowanych danych, mechanizmów nadzoru, odpowiedzialnego zarządzania ryzykiem modelu oraz rozwijania kompetencji użytkowników. Z punktu widzenia dalszych rozdziałów pracy jest to istotne tło, ponieważ w controllingu finansowym te same czynniki (dane, kontrola, kompetencje i integracja systemów) będą decydowały o tym, czy wdrożenie AI rzeczywiście poprawi efektywność procesu controllingowego. (Nesterak, Jabłoński i Kowalski, 2020)

## **2.5 Aspekty etyczne i prawne wykorzystania AI w finansach – odpowiedzialność, przejrzystość i kontrola**

Wraz z rosnącą skalą wykorzystania narzędzi AI w finansach coraz większego znaczenia nabierają kwestie etyczne i prawne, przede wszystkim dlatego, że systemy te mogą realnie wpływać na decyzje o konsekwencjach ekonomicznych (np. ocena ryzyka, rekomendacje, selekcja danych do raportów). W literaturze podkreśla się, że rozwój AI to nie tylko szansa na usprawnienia, ale również źródło nowych zagrożeń, które wymagają ustanawiania norm oraz mechanizmów nadzoru. (Stylec-Szromek, 2018)

Pierwszym kluczowym zagadnieniem jest odpowiedzialność za skutki działania AI. W praktyce organizacyjnej często pojawia się pokusa „przerzucenia” odpowiedzialności na algorytm, jednak autorzy wskazują wprost, że AI jest projektowana i wdrażana przez ludzi, a więc to człowiek (osoby i organizacje) odpowiada za sposób jej użycia i konsekwencje. (Sypniewska i Gołębiowski, 2023) W ujęciu prawnym problem odpowiedzialności jest jednym z najczęściej omawianych wątków regulacyjnych, ponieważ wymaga rozstrzygnięcia m.in. tego, kto ponosi odpowiedzialność za szkodę: twórca rozwiązania, podmiot wdrażający czy użytkownik końcowy. (Stylec-Szromek, 2018)

Drugim ważnym obszarem jest przejrzystość (transparentność) i możliwość wyjaśnienia działania systemu. W finansach znaczenie ma nie tylko wynik (np. rekomendacja), ale również uzasadnienie, które pozwala ocenić jego wiarygodność i zgodność z politykami firmy, audytem



czy wymaganiami regulacyjnymi. Zwraca się uwagę, że organizacje korzystające z AI powinny umieć w zrozumiały sposób wyjaśnić, jakie dane „wchodzą” do systemu, jakie są wyniki oraz jaki jest cel zastosowanego algorytmu. (Sypniewska i Gołębiowski, 2023) Ten postulat jest szczególnie istotny w środowisku controllingowym, gdzie decyzje i raporty muszą być możliwe do obrony (np. podczas dyskusji z zarządem) i porównywalne w czasie.

Trzecia grupa zagadnień dotyczy ryzyka nadużyć, stronniczości i naruszenia praw jednostki. W literaturze etycznej wskazuje się, że narzędzia AI mogą stać się elementem systemów nadmiernej kontroli, prowadzić do niesprawiedliwości (np. błędnej klasyfikacji) lub utrwaląc uprzedzenia, jeśli uczą się na danych historycznie obciążonych stronniczością. (Sypniewska i Gołębiowski, 2023) Choć przykłady w publikacjach często odnoszą się do zastosowań społecznych, wnioski można przenieść na grunt finansów: modele mogą dyskryminować pośrednio (np. przez dobór cech), a błędy klasyfikacji mogą przekładać się na wymierne skutki ekonomiczne lub reputacyjne.

Czwartą kwestią jest rola regulacji i kontroli instytucjonalnej. Zwraca się uwagę, że rozwój AI zwiększa znaczenie działań legislacyjnych (zwłaszcza na poziomie UE), a jednocześnie powoduje, że zagadnienia związane z wdrażaniem i funkcjonowaniem AI stają się przedmiotem zainteresowania organów kontrolnych. (Robaczyński, 2022) Z perspektywy organizacji oznacza to potrzebę przygotowania się do oceny nie tylko samej technologii, lecz przede wszystkim efektów jej stosowania: czy wdrożenie było uzasadnione, czy otoczenie organizacyjne było przygotowane na działanie systemu oraz czy istnieją mechanizmy korygowania skutków jego działania. (Robaczyński, 2022)

W praktyce wdrożeń coraz częściej podkreśla się również znaczenie podejścia „etyka i prawo od początku” (już na etapie projektowania i wdrożenia). W literaturze wskazuje się m.in. na potrzebę zespołów interdyscyplinarnych i różnorodnych (nie tylko inżynierów), które uwzględniają perspektywę biznesową, prawną i etyczną. (Sypniewska i Gołębiowski, 2023) Takie podejście jest istotne w finansach i controllingu, ponieważ pozwala ograniczać ryzyko wdrożeniowe, a jednocześnie zwiększa zaufanie do narzędzi AI jako wsparcia, a nie „czarnej skrzynki”.

Podsumowując, etyczne i prawne aspekty AI w finansach koncentrują się na odpowiedzialności za decyzje, przejrzystości modeli, ochronie przed stronniczością oraz zapewnieniu możliwości kontroli i korekty skutków działania systemu. W kolejnych częściach pracy wątki te będą szczególnie ważne przy analizie wdrożeń AI w controllingu, gdzie kluczowe są: wiarygodność danych, możliwość uzasadnienia wniosków oraz utrzymanie kontroli nad procesem analitycznym.



## ROZDZIAŁ 3. OBSZARY CONTROLLINGU WSPIERANE PRZEZ AI – ANALIZA LITERATURY I RAPORTÓW

### 3.1 Prognozowanie i planowanie z wykorzystaniem AI

Prognozowanie i planowanie finansowe należą do kluczowych zadań controllingu, ponieważ pozwalają menedżerom wyznaczać cele i alokować zasoby w sposób, który wspiera strategię przedsiębiorstwa. Literatura podkreśla, że wysokiej jakości prognozy i plany są jednym z wyróżników silnej funkcji finansowej, a w dynamicznym lub niepewnym otoczeniu biznesowym ich rola wzrasta jeszcze bardziej. Duże znaczenie ma tu big data – rosnąca dostępność różnorodnych danych oraz rozwój technik analitycznych. Coraz więcej firm korzysta z dedykowanych zespołów FP&A (Financial Planning & Analysis), które łączą dane historyczne, operacyjne i zewnętrzne, aby dostarczać prognozy i plany w krótkim czasie. (Wasserbacher i Spindler, 2022)

Sztuczna inteligencja – w tym przede wszystkim uczenie maszynowe – dobrze sprawdza się w zadaniach predykcyjnych, takich jak szacowanie przychodów, kosztów czy przepływów pieniężnych. Modele uczą się na dużych zbiorach danych i potrafią wychwycić wzorce niedostrzegalne dla klasycznych metod. Badania wskazują, że techniki te są już z powodzeniem stosowane w obszarach takich jak wykrywanie oszustw czy prognozowanie sprzedaży. Trzeba jednak pamiętać, że planowanie i alokacja zasobów mają charakter przyczynowy – wymagają zrozumienia, jakie działania wywołują konkretne skutki. Autorzy podkreślają, że naiwne stosowanie modeli predykcyjnych w planowaniu może prowadzić do błędów i zalecają wykorzystanie metod łączących uczenie maszynowe z analizą przyczynową, takich jak double machine learning (Wasserbacher i Spindler, 2022).

Rozwój cyfrowych systemów planistycznych i integracja danych powodują, że działy controllingu działają dziś w środowisku określanym mianem big data. Obejmuje ono zarówno rosnącą liczbę obserwacji (wolumen), przyspieszenie przepływu informacji (prędkość), jak i poszerzanie zakresu analizowanych danych (różnorodność). Ekspertki zwracają uwagę, że w takich warunkach rośnie znaczenie automatycznej analizy w czasie rzeczywistym i opartej na danych planowania. (Wasserbacher i Spindler, 2022) Umożliwia to np. aktualizowanie prognoz na bieżąco, szybkie reagowanie na zmiany w otoczeniu oraz łączenie danych finansowych z czynnikami makroekonomicznymi czy informacjami rynkowymi. Aby w pełni wykorzystać potencjał AI w prognozowaniu i planowaniu, niezbędna jest jednak odpowiednia infrastruktura informatyczna, spójne źródła danych oraz kompetencje analityczne w zespołach controllingu.



### **3.2 Automatyzacja procesów budżetowych i raportowania – przykłady narzędzi, które usprawniają tworzenie zestawień i raportów**

Rosnąca złożoność otoczenia biznesowego oraz duża liczba danych powodują, że przygotowywanie budżetów i raportów wyłącznie w sposób ręczny staje się coraz mniej efektywne. W odpowiedzi na to organizacje wdrażają narzędzia, które automatyzują zbieranie danych, ich porządkowanie, a następnie generowanie zestawień i raportów. W praktyce controllingowej szczególnie widoczne jest łączenie robotyzacji procesów (RPA) z elementami analityki danych oraz rozwiązaniami wykorzystującymi sztuczną inteligencję. (Pypłacz i Sasak, 2022)

Robotyzacja procesów (RPA) polega na tym, że „robot” programowy wykonuje powtarzalne czynności na aplikacjach i systemach podobnie jak pracownik (np. kopiuje dane, uzupełnia formularze, porównuje pliki, generuje cykliczne raporty). Dzięki temu część działań budżetowych i raportowych, takich jak konsolidacja danych z wielu źródeł, przygotowanie cyklicznych raportów czy wstępne uzgadnianie danych, może zostać zrealizowana szybciej i z mniejszym ryzykiem błędów wynikających z pracy ręcznej. (Ribeiro, Lima, Eckhardt i Paiva, 2021) Jednocześnie literatura wskazuje, że skuteczność RPA rośnie, gdy automatyzacja jest spójna z celami biznesowymi i odpowiednio „wpisana” w procesy organizacji (a nie traktowana wyłącznie jako doraźne narzędzie do zastąpienia pracy człowieka). (Zhang i Liu, 2019)

W obszarze budżetowania coraz częściej stosuje się także platformy i rozwiązania wspierające tzw. cyfrową transformację budżetowania, gdzie duży nacisk kładzie się na automatyczne przetwarzanie danych, bieżące aktualizowanie planów oraz raportowanie w krótszych cyklach. W tym ujęciu narzędzia automatyzujące proces budżetowy mogą ograniczać czas przygotowania danych wejściowych, ułatwiać agregację danych z systemów finansowo-księgowych oraz zwiększać przejrzystość procesu planowania (np. poprzez automatyczne wersjonowanie budżetów lub lepszą kontrolę zmian). (Salahudin, Sihidi, Karida i Firdaus, 2024)

Automatyzacja raportowania dotyczy również rozwiązań powiązanych z raportowaniem finansowym i obowiązkami sprawozdawczymi. W literaturze podkreśla się rosnące znaczenie ustrukturyzowanych formatów danych oraz narzędzi, które wspierają automatyczne przygotowanie i weryfikację raportów, co ma wpływ na jakość danych oraz ograniczenie liczby błędów. (Czyżewski i Karwowski, 2025) Z perspektywy controllingu oznacza to przesunięcie akcentu z ręcznego „składania” raportu na kontrolę jakości danych, interpretację wyników oraz wsparcie menedżerów w podejmowaniu decyzji.



Podsumowując, automatyzacja budżetowania i raportowania w controllingu opiera się głównie na: (1) RPA do przejmowania powtarzalnych działań operacyjnych, (2) narzędziach analitycznych i (w szerszym ujęciu) AI do wspierania przetwarzania informacji oraz (3) platformach cyfrowych, które porządkują proces planowania i raportowania w organizacji. Efektem jest skrócenie czasu przygotowania zestawień, większa spójność danych oraz możliwość częstszego raportowania na potrzeby zarządcze.

### **3.3 Analiza rentowności i controlling kosztów – rola AI w identyfikacji kosztów, analizie rentowności i optymalizacji marż**

Analiza rentowności oraz controlling kosztów należą do podstawowych obszarów controllingu finansowego. Tradycyjnie opierają się one na analizie wskaźników rentowności oraz ich dekompozycji (np. marży operacyjnej, rotacji aktywów czy struktury finansowania). Współczesne badania pokazują jednak, że zastosowanie metod uczenia maszynowego pozwala zwiększyć dokładność prognoz przyszłej rentowności oraz lepiej identyfikować źródła zmian wyników finansowych. (Binz, Schipper i Standridge, 2025)

Badania O. Binza, K. Schipper i K.R. Standridge (2025) wskazują, że wykorzystanie nieliniowych metod uczenia maszynowego w estymacji ram dekompozycji rentowności prowadzi do istotnie dokładniejszych prognoz niż modele liniowe czy modele oparte wyłącznie na danych historycznych. (Binz, Schipper i Standridge, 2025) Autorzy podkreślają również, że szczególnie istotne jest oddzielenie pozycji operacyjnych od finansowych oraz koncentracja na tzw. pozycjach podstawowych (core items), co zwiększa trafność prognoz. (Binz, Schipper i Standridge, 2025)

Z kolei klasyczna koncepcja dekompozycji rentowności zaproponowana przez D. Nissima i S.H. Penmana pokazuje, że analiza relacji między marżą sprzedaży, rotacją aktywów oraz poziomem dźwigni finansowej pozwala lepiej zrozumieć źródła zyskowności przedsiębiorstwa. (Nissim i Penman, 2003) Integracja tej koncepcji z narzędziami AI umożliwia jednoczesną analizę wielu zmiennych oraz wychwycenie zależności nieliniowych, które w tradycyjnych modelach mogą pozostać niewidoczne.

W praktyce controlling kosztów z wykorzystaniem AI może obejmować identyfikację czynników kosztotwórczych, segmentację kosztów według ich zmienności, analizę wpływu zmian struktury kosztów na poziom marży oraz symulację scenariuszy optymalizacyjnych. Literatura dotycząca zarządzania kapitałem przedsiębiorstwa wskazuje, że integracja sztucznej inteligencji z analizą danych finansowych i operacyjnych sprzyja poprawie efektywności oraz wzrostowi rentowności przedsiębiorstwa. (Walicka i Czemieli-Grzybowska, 2023)



Oznacza to, że rola AI w controllingu kosztów nie ogranicza się jedynie do automatyzacji przetwarzania danych. Kluczowe znaczenie ma możliwość bardziej precyzyjnej analizy zależności między kosztami, przychodami i strukturą aktywów, a w konsekwencji – podejmowania decyzji optymalizacyjnych dotyczących marż.

### **3.4 Zarządzanie ryzykiem i płynnością – wykorzystanie modeli predykcyjnych do oceny ryzyka i monitorowania płynności**

Zarządzanie ryzykiem oraz płynnością finansową stanowi jeden z kluczowych obszarów controllingu, szczególnie w warunkach zmienności rynkowej i rosnącej niepewności makroekonomicznej. Tradycyjnie ocena ryzyka opierała się na analizie wskaźnikowej, modelach scoringowych oraz historycznych danych finansowych. Współcześnie coraz częściej wykorzystuje się jednak modele predykcyjne oparte na uczeniu maszynowym, które umożliwiają analizę dużych zbiorów danych i identyfikację złożonych zależności między zmiennymi. (Singh, Choubey i Sauer, 2024)

Badania dotyczące prognozowania płynności wskazują, że modele uczenia maszynowego mogą poprawiać dokładność prognoz przepływów pieniężnych zarówno na poziomie całego przedsiębiorstwa, jak i jednostek zależnych. (Singh, Choubey i Sauer, 2024) Autorzy podkreślają, że wykorzystanie algorytmów takich jak gradient boosting czy sieci neuronowe pozwala uwzględnić większą liczbę zmiennych operacyjnych i rynkowych niż w klasycznych modelach regresyjnych. (Singh, Choubey i Sauer, 2024) W praktyce controllingu oznacza to możliwość wcześniejszego wykrywania zagrożeń płynności oraz lepszego planowania struktury finansowania.

Modele predykcyjne znajdują również zastosowanie w ocenie ryzyka kredytowego oraz ryzyka kontrahenta. Literatura wskazuje, że połączenie modelowania statystycznego z uczeniem maszynowym umożliwia bardziej precyzyjne szacowanie prawdopodobieństwa niewypłacalności oraz identyfikację czynników zwiększających ryzyko utraty płynności. (Bercz, 2022) Z punktu widzenia controllingu istotne jest, że modele te mogą być wykorzystywane nie tylko w instytucjach finansowych, lecz także w przedsiębiorstwach niefinansowych – np. do monitorowania terminowości należności i analizy ekspozycji na ryzyko branżowe.

W kontekście wdrożeń AI w sektorze finansowym istotne znaczenie ma również wymiar regulacyjny. Dokument rządowy dotyczący rekomendacji w zakresie sztucznej inteligencji w sektorze finansowym podkreśla, że implementacja modeli AI powinna być oparta na podejściu risk-based, uwzględniającym bezpieczeństwo danych, stabilność systemu



finansowego oraz możliwość nadzoru nad algorytmami. (Bercz, 2022) Dokument wskazuje, że instytucje powinny zapewnić przejrzystość modeli, możliwość ich weryfikacji oraz odpowiedzialność za decyzje podejmowane z wykorzystaniem AI. (Bercz, 2022)

Z perspektywy controllingu oznacza to konieczność łączenia potencjału modeli predykcyjnych z odpowiednimi procedurami kontroli i monitorowania ich działania. Modele prognozujące płynność czy ryzyko kredytowe powinny być regularnie walidowane, a ich wyniki interpretowane w kontekście specyfiki działalności przedsiębiorstwa. Wdrożenie narzędzi AI w obszarze zarządzania ryzykiem nie eliminuje odpowiedzialności menedżerów, lecz rozszerza zakres dostępnych informacji i umożliwia bardziej świadome podejmowanie decyzji finansowych.

Podsumowując, wykorzystanie modeli predykcyjnych w zarządzaniu ryzykiem i płynnością pozwala: (1) zwiększyć dokładność prognoz przepływów pieniężnych, (2) wcześniej identyfikować zagrożenia utraty płynności, (3) poprawić ocenę ryzyka kontrahenta, (4) integrować analizę finansową z wymogami regulacyjnymi dotyczącymi stosowania AI.

### **3.5 Monitoring należności i płatności – zastosowanie AI w ograniczaniu ryzyka zatorów płatniczych**

Monitoring należności i zobowiązań stanowi kluczowy element controllingu operacyjnego, ponieważ bezpośrednio wpływa na poziom płynności finansowej przedsiębiorstwa. W warunkach rosnącej niepewności gospodarczej coraz częściej wykorzystuje się modele predykcyjne umożliwiające prognozowanie opóźnień w płatnościach oraz identyfikację kontrahentów generujących podwyższone ryzyko kredytowe. (Bercz, 2022)

Algorytmy uczenia maszynowego – takie jak gradient boosting czy sieci neuronowe – wykazują wyższą skuteczność w prognozowaniu niewypłacalności niż klasyczne modele regresyjne. (Bercz, 2022) Zastosowanie tych metod pozwala estymować prawdopodobieństwo opóźnienia płatności (PD) oraz identyfikować wzorce zachowań kontrahentów poprzedzające utratę płynności. (Bercz, 2022)

W kontekście zarządzania płynnością badania nad prognozowaniem przepływów pieniężnych wskazują, że modele ML poprawiają dokładność estymacji krótkoterminowych cash flow zarówno na poziomie całej organizacji, jak i jej jednostek zależnych. (Singh, Choubey i Sauer, 2024) Pozwala to wcześniej identyfikować luki płynnościowe oraz planować finansowanie krótkoterminowe.

Rozszerzenie analizy o parametry EAD (Exposure at Default) i LGD (Loss Given Default) umożliwia bardziej kompleksową ocenę ryzyka należności. (Singh, Choubey i Sauer,



2024) Takie podejście zbliża monitoring należności w przedsiębiorstwach niefinansowych do standardów stosowanych w sektorze bankowym.

Z perspektywy operacyjnej automatyzacja monitoringu może być wspierana przez rozwiązania RPA, które umożliwiają generowanie cyklicznych raportów, klasyfikację kontrahentów według poziomu ryzyka oraz automatyczne przypomnienia o płatnościach. (Ribeiro, Lima, Eckhardt i Paiva, 2021) Integracja robotyzacji z modelami predykcyjnymi pozwala przejść od podejścia reaktywnego do proaktywnego.

Jednocześnie wdrożenie modeli AI w obszarze monitoringu należności powinno być zgodne z podejściem risk-based oraz zasadami nadzoru nad algorytmami, co podkreślają rekomendacje dotyczące stosowania sztucznej inteligencji w sektorze finansowym. (Eksperti Grupy Roboczej ds. Sztucznej Inteligencji, 2022)

Podsumowując, wykorzystanie AI w monitoringu należności i płatności pozwala na wcześniejszą identyfikację ryzyka, poprawę prognoz przepływów pieniężnych oraz ograniczenie zatorów płatniczych przy zachowaniu wymogów regulacyjnych.

### **3.6 Przegląd literatury i raportów branżowych – podsumowanie najnowszych wyników badań i raportów dotyczących AI w controllingu**

Dotychczasowy przegląd literatury wskazuje, że zastosowanie sztucznej inteligencji w controllingu finansowym rozwija się równolegle w dwóch wymiarach: akademickim oraz praktyczno-branżowym. W ujęciu naukowym dominuje analiza wpływu AI na procesy decyzyjne, efektywność analiz finansowych oraz jakość prognoz, natomiast raporty branżowe koncentrują się na aspektach wdrożeniowych, organizacyjnych i kompetencyjnych.

W literaturze podkreśla się, że rozwój AI w finansach jest elementem szerszej transformacji cyfrowej organizacji, w której controlling przestaje pełnić wyłącznie funkcję kontrolną, a coraz częściej staje się partnerem biznesowym wspierającym zarząd w podejmowaniu decyzji strategicznych. (Krystian i Zaskórski, 2023) Wskazuje się, że wykorzystanie zaawansowanej analityki danych oraz uczenia maszynowego umożliwia przejście od analiz historycznych do modeli predykcyjnych i preskrypcyjnych, co zwiększa wartość informacyjną raportów controllingowych. (Krystian i Zaskórski, 2023)

Badania opublikowane w czasopiśmie *Przegląd Organizacji* zwracają uwagę na rosnące znaczenie kompetencji cyfrowych menedżerów w kontekście AI. Analiza trendów literaturowych oraz zainteresowania internautów pokazuje, że kompetencje związane z rozumieniem algorytmów, analizą danych oraz współpracą z systemami AI stają się jednym z kluczowych elementów nowoczesnego zarządzania. (Szafranowicz, 2025) Oznacza to, że



rozwój AI w controllingu nie dotyczy wyłącznie technologii, lecz także transformacji roli controllera.

W raportach branżowych, w tym analizach sektora usług biznesowych (GBS), wskazuje się, że robotyzacja procesów (RPA) oraz inteligentna automatyzacja (IPA) pozwalają znacząco ograniczyć koszty operacyjne oraz zwiększyć dokładność raportowania finansowego. (Nesterak, 2025) W szczególności podkreśla się możliwość automatyzacji takich procesów jak konsolidacja danych, uzgadnianie sald, raportowanie cykliczne czy analiza odchyleń budżetowych. Jednocześnie zauważa się, że automatyzacja wymaga zapewnienia odpowiedniego nadzoru oraz wysokiej jakości danych wejściowych.

Z kolei artykuły dotyczące wyzwań wykorzystania nowoczesnych technologii AI w rachunkowości i podatkach akcentują ryzyka związane z błędami algorytmicznymi, problemami interpretacyjnymi oraz brakiem transparentności modeli („black box”). (Czyżewski i Karwowski, 2025) W kontekście controllingu oznacza to konieczność zachowania równowagi między automatyzacją a kontrolą merytoryczną wyników generowanych przez systemy AI.

W opracowaniach międzynarodowych wskazuje się ponadto, że AI w obszarze finansów przyczynia się do skrócenia cyklu budżetowego, zwiększenia precyzji prognoz oraz poprawy jakości analiz scenariuszowych. (Ayari, Guetari i Kraïem, 2026) Jednocześnie autorzy podkreślają, że pełne wykorzystanie potencjału AI wymaga integracji systemów informatycznych, standaryzacji procesów oraz inwestycji w rozwój kompetencji analitycznych pracowników.

Raporty organizacji branżowych wskazują także na rosnące znaczenie tzw. explainable AI (XAI), czyli modeli umożliwiających interpretację i uzasadnienie decyzji podejmowanych przez algorytmy. (Eksperti Grupy Roboczej ds. Sztucznej Inteligencji, 2022) W controllingu finansowym ma to szczególne znaczenie ze względu na odpowiedzialność za raportowane dane oraz konieczność zapewnienia zgodności z regulacjami prawnymi i zasadami ładu korporacyjnego.

W literaturze przedmiotu coraz wyraźniej podkreśla się, że rozwój sztucznej inteligencji istotnie wpływa na funkcjonowanie działów finansowych oraz controllingu. Zmiana ta dotyczy zarówno sposobu przetwarzania danych, jak i roli controllera w organizacji. Współczesne badania koncentrują się przede wszystkim na wykorzystaniu uczenia maszynowego (machine learning), analityki predykcyjnej oraz automatyzacji procesów raportowych.

Jordan i Mitchell wskazują, że uczenie maszynowe stanowi jeden z najszybciej rozwijających się obszarów AI, znajdujący szerokie zastosowanie w analizie danych



finansowych. (Jordan i Mitchell, 2015) Z kolei Shmueli podkreśla rozróżnienie pomiędzy podejściem wyjaśniającym a predykcyjnym, wskazując, że w praktyce biznesowej coraz większe znaczenie ma trafność prognoz. (Shmueli, 2010) W kontekście controllingu oznacza to przesunięcie akcentu z raportowania danych historycznych na prognozowanie i symulację przyszłych scenariuszy.

Agrawal, Gans i Goldfarb zauważają, że największą wartość ekonomiczną AI generuje poprzez obniżenie kosztu predykcji. (Agrawal, Gans i Goldfarb, 2018) Davenport i Kirby wskazują natomiast, że rozwój systemów kognitywnych nie eliminuje roli specjalistów finansowych, lecz zmienia jej charakter – z operacyjnego na analityczno-doradczy. (Davenport i Kirby, 2015) Podobne wnioski formułują Brynjolfsson i McAfee, podkreślając komplementarność człowieka i technologii. (Brynjolfsson i McAfee, 2014)

W obszarze rachunkowości i audytu badacze analizują wpływ analityki danych i automatyzacji na efektywność procesów finansowych. Kokina i Davenport wskazują, że zastosowanie AI w audycie i rachunkowości zwiększa zakres analizowanych danych oraz pozwala na bieżące monitorowanie ryzyk. (Kokina i Davenport, 2017) Appelbaum, Kogan i Vasarhelyi podkreślają znaczenie big data i analityki w podnoszeniu jakości informacji zarządczej. (Appelbaum, Kogan i Vasarhelyi, 2017) Richins i współautorzy zwracają uwagę, że transformacja cyfrowa wymusza zmianę kompetencji księgowych i controllerów. (Richins, Stapleton, Stratopoulos i Wong, 2017)

Istotny nurt badań dotyczy prognozowania finansowego z wykorzystaniem metod statystycznych i uczenia maszynowego. Makridakis i współautorzy wykazują, że metody ML w wielu przypadkach osiągają wyższą trafność prognoz niż tradycyjne modele statystyczne. (Makridakis, Spiliotis i Assimakopoulos, 2018) Begenau, Farboodi i Veldkamp analizują wpływ dużych zbiorów danych na modele finansowe. (Begenau, Farboodi i Veldkamp, 2018)

W literaturze podkreśla się również ryzyka związane z wykorzystaniem AI w finansach. Barocas i Selbst wskazują na problem uprzedzeń algorytmicznych. (Barocas i Selbst, 2016) Doshi-Velez i Kim zwracają uwagę na potrzebę rozwoju metod zapewniających interpretowalność modeli. (Doshi-Velez i Kim, 2017) Z perspektywy instytucjonalnej Bank Rozrachunków Międzynarodowych (BIS) oraz Europejski Urząd Nadzoru Bankowego (EBA) akcentują konieczność zarządzania ryzykiem modeli. (Supervision, Basel Committee on Banking, 2018)

W kontekście regulacyjnym coraz większe znaczenie mają inicjatywy międzynarodowe. OECD wskazuje na potrzebę odpowiedzialnego stosowania AI (Anggun, Sariwulan i Husein,



2023), natomiast projekt unijnego AI Act wprowadza podejście oparte na analizie ryzyka. (Komisja Europejska, 2021)

Podsumowując, literatura naukowa i raporty branżowe są zgodne co do kilku kluczowych wniosków: (1) AI zwiększa efektywność i precyzję analiz controllingowych, (2) największy potencjał tkwi w obszarze prognozowania i analizy scenariuszowej, (3) wdrożenie AI wymaga odpowiednich kompetencji cyfrowych i analitycznych, (4) istotne są kwestie etyczne, regulacyjne i związane z jakością danych.

Można zatem stwierdzić, że rozwój AI w controllingu finansowym ma charakter ewolucyjny – nie zastępuje controllera, lecz redefiniuje jego rolę. Controller przyszłości będzie łączył kompetencje finansowe z umiejętnością interpretacji wyników generowanych przez systemy sztucznej inteligencji, pełniąc funkcję integratora wiedzy technologicznej i biznesowej.



## **ROZDZIAŁ 4. BADANIA WŁASNE: METODOLOGIA I ANALIZA WYNIKÓW ANKIETY**

### **4.1 Metodologia badań własnych**

Celem badań własnych było zweryfikowanie hipotez postawionych w pracy oraz poznanie opinii praktyków na temat wykorzystania sztucznej inteligencji w controllingu finansowym. Badanie miało charakter empiryczny i zostało przeprowadzone z wykorzystaniem dwóch metod: ankiety internetowej oraz indywidualnego wywiadu pogłębionego z ekspertem.

Zastosowanie dwóch metod badawczych pozwoliło na uzyskanie zarówno danych ilościowych, jak i jakościowych. Ankieta umożliwiła zebranie opinii większej grupy respondentów oraz przeprowadzenie podstawowej analizy statystycznej. Wywiad natomiast pozwolił na pogłębienie wybranych zagadnień, lepsze zrozumienie kontekstu organizacyjnego oraz identyfikację praktycznych aspektów wdrażania AI w controllingu.

#### **4.1.1 Charakterystyka ankiety**

Ankieta została przeprowadzona w formie online i była skierowana do osób pracujących w obszarze finansów, controllingu oraz analizy danych finansowych. Kwestionariusz składał się z siedmiu sekcji:

- metryczki (profil respondenta i organizacji),
- oceny dojrzałości danych i narzędzi,
- zakresu wykorzystania AI w controllingu,
- postrzeganych korzyści,
- postrzeganych ryzyk,
- barier wdrożeniowych,
- oceny poziomu wiedzy, zaufania i przyszłości AI w controllingu.

W pytaniach zamkniętych zastosowano głównie skalę Likerta od 1 do 5, gdzie 1 oznaczało najniższy poziom zgody, a 5 – najwyższy. Pozwoliło to na obliczenie średnich ocen i dokonanie porównań pomiędzy poszczególnymi obszarami.

W celu uproszczenia analizy, dla części pytań dotyczących korzyści (sekcja D) oraz ryzyk (sekcja E) obliczono średnią ocenę zbiorczą, co pozwoliło na ogólną ocenę postrzegania AI



jako szanse lub zagrożenia. Analiza miała charakter statystyki opisowej i obejmowała średnie wartości odpowiedzi oraz porównania wybranych zmiennych (np. poziomu wykorzystania AI i oceny korzyści).

#### **4.1.2 Charakterystyka wywiadu**

Drugą metodą badawczą był wywiad indywidualny przeprowadzony z ekspertem – Senior Financial Controllerem pracującym w międzynarodowej organizacji. Wywiad miał charakter półstrukturyzowany, co oznacza, że opierał się na przygotowanym wcześniej zestawie pytań, ale dopuszczał swobodę wypowiedzi i rozwinięcie wybranych wątków.

Rozmowa dotyczyła m.in.: poziomu cyfryzacji i integracji systemów, jakości danych finansowych, zakresu wykorzystania AI w praktyce, korzyści i ryzyk związanych z wdrożeniem, zmian w pracy controllera, przyszłości zawodu w kontekście rozwoju sztucznej inteligencji.

Wywiad pozwolił na skonfrontowanie wyników ankiety z praktycznym doświadczeniem osoby bezpośrednio zaangażowanej w procesy controllingowe.

### **4.2 Analiza wyników badania ankietowego i wywiadu**

#### **4.2.1 Wyniki badania ankietowego – ujęcie ogólne**

Analiza wyników ankiety pozwoliła na ocenę stopnia wykorzystania AI w controllingu finansowym oraz postrzegania jej jako narzędzia wspierającego procesy decyzyjne.

W pierwszej kolejności przeanalizowano zakres wykorzystania AI w organizacjach respondentów. Odpowiedzi wskazują, że sztuczna inteligencja jest wykorzystywana głównie w obszarach takich jak prognozowanie finansowe, analiza odchyleń oraz automatyzacja raportowania. Rzadziej wskazywano na zaawansowane modele predykcyjne czy kompleksowe systemy oparte wyłącznie na AI.

W odniesieniu do postrzeganych korzyści respondenci najwyżej oceniali skrócenie czasu przygotowania raportów oraz możliwość szybszego wykrywania odchyleń. Wysoko oceniano również wpływ AI na poprawę trafności prognoz w stabilnych obszarach działalności. Średnia ocena wszystkich stwierdzeń dotyczących korzyści wskazuje, że AI jest postrzegana raczej pozytywnie i jako realne wsparcie w pracy controllera.

Jednocześnie zauważalne są obawy związane z jakością danych oraz trudnością wyjaśnienia działania modeli (tzw. efekt „czarnej skrzynki”). Średnia ocena stwierdzeń dotyczących ryzyk pokazuje, że respondenci dostrzegają potencjalne zagrożenia, jednak nie dominują one nad oceną korzyści.



W zakresie barier wdrożeniowych najczęściej wskazywano brak kompetencji w obszarze danych i AI, problemy z jakością oraz integracją danych, a także ograniczone zasoby czasowe. Wyniki te są spójne z wcześniejszymi rozważaniami teoretycznymi zawartymi w pracy.

#### **4.2.2 Wnioski z wywiadu eksperckiego**

Wyniki wywiadu w dużej mierze potwierdzają obserwacje z badania ankietowego. Ekspert wskazał, że największe korzyści z wykorzystania AI widoczne są w prognozowaniu oraz analizie odchyleń, gdzie dostępne są duże zbiory danych historycznych. Podkreślono również oszczędność czasu oraz możliwość szybszego identyfikowania nieprawidłowości.

Jednocześnie rozmówca zwrócił uwagę na kluczową rolę jakości danych. Według eksperta bez uporządkowanych, spójnych i zintegrowanych danych wdrożenie AI nie przynosi oczekiwanych rezultatów. Wskazano również na problem „czarnej skrzynki”, czyli trudności w pełnym wyjaśnieniu działania bardziej zaawansowanych modeli.

Istotnym wnioskiem z wywiadu jest także zmiana charakteru pracy controllera. AI nie zastępuje specjalistów, lecz przejmuje część zadań rutynowych, co pozwala skoncentrować się na analizie, interpretacji danych i współpracy z biznesem. Rola controllera staje się bardziej doradcza i strategiczna.

Ekspert podkreślił również, że zaufanie do AI rośnie wraz z doświadczeniem organizacji w pracy z modelami oraz z ich skutecznością w praktyce. Jednocześnie zaznaczył, że AI powinna być traktowana jako narzędzie wspierające, a nie zastępujące człowieka w procesie podejmowania decyzji.

#### **4.3 Charakterystyka próby badawczej**

W badaniu ankietowym wzięło udział 100 respondentów związanych zawodowo z obszarem finansów, controllingu oraz analizy danych finansowych. Dobór próby miał charakter celowy – kwestionariusz został skierowany do osób pracujących w działach finansowych przedsiębiorstw funkcjonujących w Polsce, w tym również w organizacjach o zasięgu międzynarodowym. Przyjęta liczebność próby pozwala na przeprowadzenie analizy statystycznej o charakterze opisowym oraz sformułowanie wniosków odnoszących się do praktyki rynkowej.

Najliczniejszą grupę badanych stanowili controllerzy finansowi oraz specjaliści ds. controllingu (około 40% respondentów). Istotny udział mieli również analitycy finansowi i FP&A (około 20%), a także menedżerowie finansów i CFO (około 12%). W badaniu uczestniczyli także przedstawiciele księgowości oraz osoby odpowiedzialne za analizę danych



i rozwiązania IT w obszarze finansów. Taka struktura stanowisk pozwala uznać, że uzyskane odpowiedzi odzwierciedlają zarówno perspektywę operacyjną, jak i zarządczą oraz technologiczną.

Respondenci reprezentowali zróżnicowany poziom doświadczenia zawodowego. Największą grupę stanowiły osoby z 4–7-letnim stażem pracy oraz z doświadczeniem 8–12 lat. Znaczący udział miały również osoby pracujące w finansach ponad 12 lat. Mniejszą część próby stanowiły osoby z krótszym doświadczeniem (1–3 lata), natomiast najmniej liczną grupę – respondenci rozpoczynający dopiero karierę zawodową. Oznacza to, że w badaniu przeważały osoby posiadające praktyczne doświadczenie w controllingu i analizie finansowej, co zwiększa wiarygodność uzyskanych opinii.

Pod względem wielkości organizacji dominowały przedsiębiorstwa średnie i duże. Blisko połowa respondentów pracuje w firmach zatrudniających powyżej 1000 pracowników, a około jedna czwarta w organizacjach liczących od 250 do 999 pracowników. Mniejszy udział miały podmioty z sektora małych i średnich przedsiębiorstw. W strukturze kapitałowej przeważały firmy o charakterze międzynarodowym, co jest zgodne z rosnącą rolą centrów usług wspólnych (SSC/GBS) oraz oddziałów globalnych korporacji w Polsce. Wśród reprezentowanych branż najczęściej wskazywano sektor SSC/GBS, produkcję, usługi oraz finanse.

Analiza odpowiedzi dotyczących dojrzałości danych wskazuje, że większość respondentów ocenia jakość danych finansowych w swoich organizacjach jako umiarkowanie wysoką lub wysoką. Podobnie oceniany jest poziom integracji systemów, takich jak ERP, hurtownie danych czy narzędzia Business Intelligence, choć w mniejszych podmiotach widoczny jest niższy poziom zaawansowania technologicznego. W praktyce oznacza to, że znaczna część badanych funkcjonuje w środowisku, które umożliwia wdrażanie bardziej zaawansowanych narzędzi analitycznych, w tym rozwiązań opartych na sztucznej inteligencji.

W zakresie wykorzystywanych narzędzi dominują arkusze kalkulacyjne oraz systemy ERP i rozwiązania BI. Coraz częściej wskazywano również na wykorzystanie automatyzacji procesów (RPA) oraz narzędzi opartych na AI, zarówno w postaci modeli analitycznych wspierających prognozowanie czy analizę odchyleń, jak i narzędzi generatywnych wspomagających raportowanie.

Odpowiedzi dotyczące stopnia wykorzystania AI pokazują, że około jedna trzecia organizacji wykorzystuje rozwiązania oparte na sztucznej inteligencji w sposób produkcyjny, a kolejne przedsiębiorstwa prowadzą pilotaże lub testy. Część respondentów deklaruje plany



wdrożenia w najbliższych miesiącach, natomiast niewielki odsetek wskazuje brak wykorzystania i brak takich planów. Wyniki te sugerują, że w 2026 roku AI w controllingu finansowym w Polsce jest już realnym narzędziem stosowanym w praktyce, choć poziom jej zaawansowania i dojrzałości jest zróżnicowany w zależności od wielkości i charakteru organizacji.

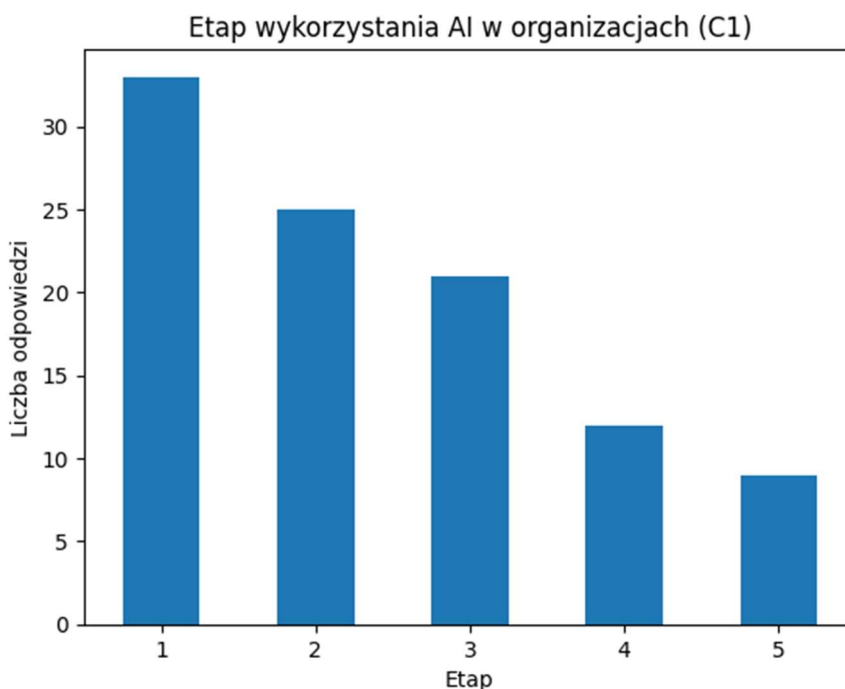
Całościowo można stwierdzić, że próba badawcza obejmuje zróżnicowaną, ale jednocześnie merytorycznie adekwatną grupę respondentów, co pozwala na sformułowanie wniosków odnoszących się do aktualnych trendów w zakresie wykorzystania sztucznej inteligencji w controllingu finansowym.

#### 4.4 Analiza wyników ankiety – poziom wykorzystania AI w controllingu finansowym

Analiza poziomu wykorzystania sztucznej inteligencji w controllingu finansowym została oparta przede wszystkim na odpowiedziach z sekcji C ankiety. W pierwszym etapie zastosowano statystykę opisową (liczebności, średnie, odchylenia standardowe), a następnie przeprowadzono wybrane testy zależności: korelację rang Spearmana, test chi-kwadrat oraz test Manna-Whitneya. Przyjęto poziom istotności  $\alpha = 0,05$ .

##### 4.4.1 Etap wykorzystania AI w organizacjach

Rozkład odpowiedzi na pytanie dotyczące etapu wykorzystania AI (C1) przedstawiono na rysunku 4.1.

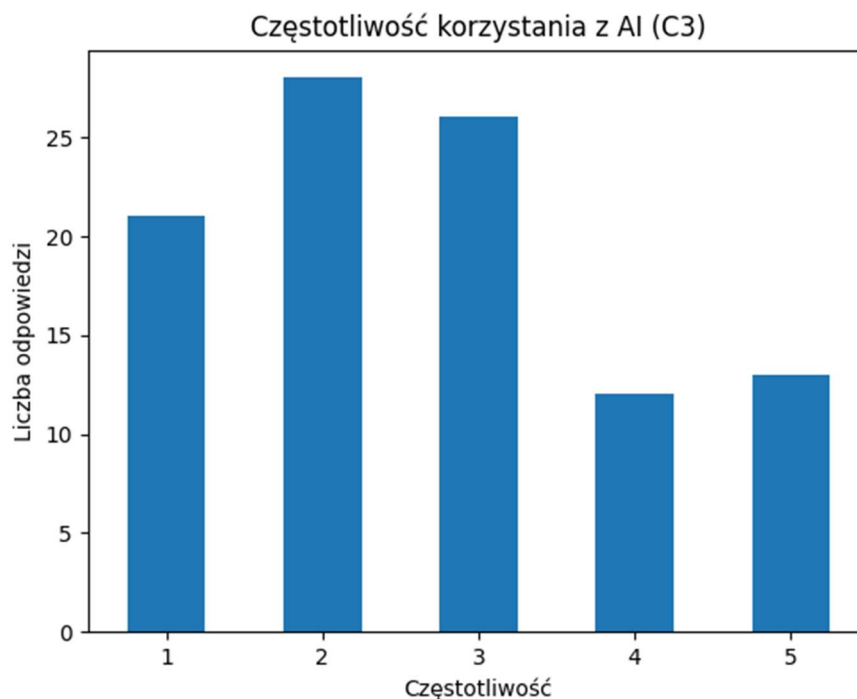


*Rysunek 4.1 Etap wykorzystania AI w organizacjach (C1)*

Źródło: opracowanie własne na podstawie wyników badań.

Z analizy wynika, że największa część badanych organizacji wykorzystuje rozwiązania AI w sposób produkcyjny, a istotna grupa znajduje się na etapie pilotażu lub testów. Mniejszy odsetek firm dopiero planuje wdrożenie lub nie podejmuje takich działań. Oznacza to, że w badanej próbie sztuczna inteligencja stanowi już element realnie funkcjonujących procesów controllingowych, choć poziom jej zaawansowania jest zróżnicowany.

Rysunek 4.2 prezentuje częstotliwość korzystania z narzędzi AI w pracy (C3).



*Rysunek 4.2 Częstotliwość korzystania z narzędzi AI w pracy (C3)*

Źródło: opracowanie własne na podstawie wyników badań.


Najczęściej respondenci deklarowali korzystanie z AI kilka razy w tygodniu lub kilka razy w miesiącu. Mniejsza grupa korzysta z narzędzi codziennie, a część – sporadycznie lub wcale. Wynik ten sugeruje, że nawet w organizacjach posiadających rozwiązania AI ich wykorzystanie nie zawsze ma charakter systematyczny i może zależeć od zakresu obowiązków oraz specyfiki procesów controllingowych.

#### 4.4.2 Dojrzałość danych a poziom wykorzystania AI

Średnia ocena jakości danych finansowych wyniosła  $M = 3,41$ , natomiast średnia ocena integracji systemów  $M = 3,59$  (skala 1–5). Wskazuje to na umiarkowanie wysoki poziom dojrzałości danych w badanych organizacjach.

W celu sprawdzenia zależności pomiędzy etapem wykorzystania AI (C1) a jakością danych (B1) zastosowano korelację rang Spearmana. Uzyskany współczynnik był bardzo niski ( $r_s \approx -0,03$ ) i nieistotny statystycznie ( $p > 0,05$ ). Analogicznie nie stwierdzono istotnej zależności w przypadku poziomym integracji systemów (B2).

Średnią ocenę jakości danych w zależności od etapu wykorzystania AI zaprezentowano na rysunku 4.3.



Rysunek 4.3 Średnia ocena jakości danych (B1) w zależności od etapu wykorzystania AI (C1)

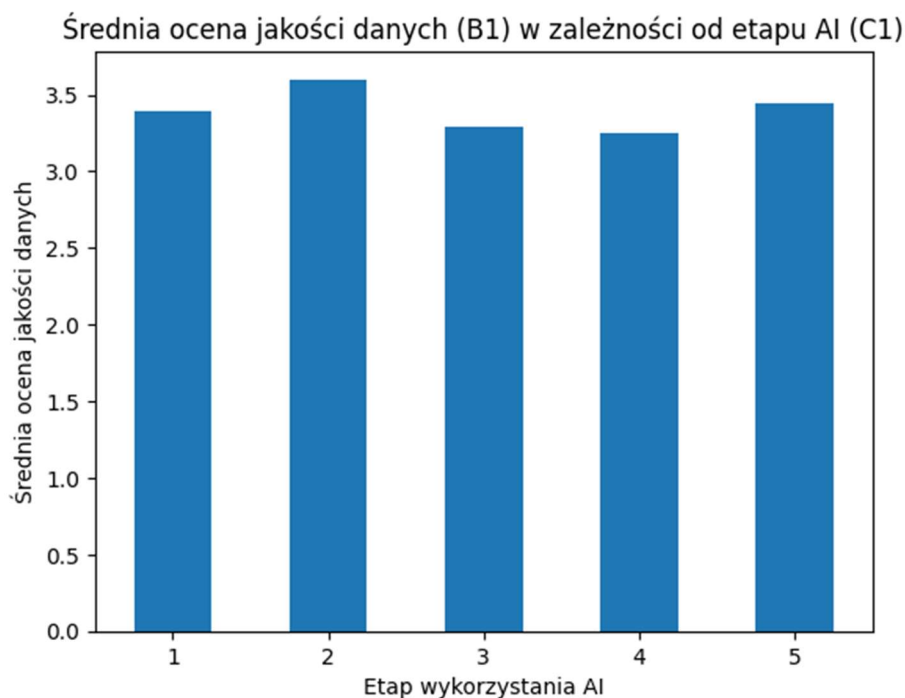
Źródło: opracowanie własne na podstawie wyników badań.

Widoczne różnice między grupami nie tworzą jednoznacznego trendu, co potwierdzają wyniki analizy statystycznej. Oznacza to, że w badanej próbie sama subiektywna ocena jakości danych nie była czynnikiem istotnie różnicującym etap wdrożenia AI.

#### 4.4.3 Korzyści i ryzyka w kontekście wykorzystania AI

Dla pełniejszego obrazu zestawiono ogólną ocenę korzyści oraz ryzyk związanych z wykorzystaniem AI. Średnia zbiorcza ocena korzyści (D1a–D1f) wyniosła  $M = 4,14$ , natomiast średnia ocena ryzyk (E1a–E1f)  $M = 3,32$ .

Porównanie tych wartości przedstawiono na rysunku 4.4.



Rysunek 4.4 Porównanie średniej oceny korzyści i ryzyk związanych z AI

Źródło: opracowanie własne na podstawie wyników badań.

Zestawienie to pokazuje wyraźną przewagę postrzeganych korzyści nad ryzykami. Oznacza to, że w badanej próbie sztuczna inteligencja jest oceniana raczej jako narzędzie wspierające efektywność i jakość analiz niż jako zagrożenie dla controllingu finansowego.

Dodatkowo porównano poziom zaufania do AI w grupach organizacji wykorzystujących AI oraz tych, które jej nie wykorzystują. Test Manna-Whitneya nie wykazał istotnej różnicy statystycznej ( $p > 0,05$ ), choć w grupie korzystającej z AI obserwowano tendencję do wyższego poziomu zaufania.

#### 4.4.4 Podsumowanie

Przeprowadzona analiza wskazuje, że wykorzystanie AI w controllingu finansowym jest w badanej próbie relatywnie rozpowszechnione, jednak jego intensywność i stopień formalizacji pozostają zróżnicowane. Nie stwierdzono istotnych statystycznie zależności pomiędzy etapem wdrożenia AI a jakością danych, integracją systemów czy wielkością organizacji. Jednocześnie wyraźna przewaga średniej oceny korzyści nad ryzykami potwierdza pozytywne postrzeżenie roli AI w controllingu finansowym.



## 4.5 Analiza wyników wywiadu

Uzupełnieniem badania ankietowego był indywidualny wywiad pogłębiony przeprowadzony z ekspertem pełniącym funkcję Senior Financial Controllera w dużej organizacji międzynarodowej. Celem wywiadu było uzyskanie szerszej, praktycznej perspektywy dotyczącej wdrażania oraz wykorzystania sztucznej inteligencji w controllingu finansowym, a także skonfrontowanie wyników ilościowych z doświadczeniami osoby bezpośrednio zaangażowanej w te procesy.


Z wypowiedzi eksperta wynika, że wykorzystanie AI w controllingu ma przede wszystkim charakter wspierający. W organizacji, w której pracuje rozmówca, rozwiązania oparte na sztucznej inteligencji są stosowane w prognozowaniu wybranych kategorii kosztów, analizie odchyleń oraz w przygotowywaniu wstępnych wersji komentarzy do raportów zarządczych. Część rozwiązań funkcjonuje już produkcyjnie, inne są nadal dostrajane i rozwijane. AI nie zastępuje jednak decyzji podejmowanych przez controllera, lecz stanowi dodatkowe źródło informacji i wsparcie analityczne.

Przed wdrożeniem elementów automatyzacji i rozwiązań opartych na AI zespół controllingu przygotowywał miesięcznie około 25–30 cyklicznych raportów, obejmujących m.in. raporty kosztów operacyjnych według centrów odpowiedzialności, raporty odchyleń budżetowych, zestawienia marżowe oraz pakiet raportowy dla zarządu. Znaczna część tych raportów wymagała ręcznej konsolidacji danych z kilku źródeł (system ERP, arkusze Excel, dane operacyjne), a następnie przygotowania komentarza opisowego.

Czas przygotowania pełnego pakietu raportów miesięcznych wynosił średnio od 3 do 5 dni roboczych pracy zespołu. Po wdrożeniu rozwiązań automatyzujących (w tym elementów RPA oraz modeli wspierających analizę anomalii) udało się zautomatyzować około 40–50% czynności związanych z pobieraniem i łączeniem danych oraz ustandaryzować strukturę raportów w narzędziu BI.

W efekcie czas przygotowania pakietu raportowego skrócił się średnio o około 25–35%, co oznacza oszczędność około 1–1,5 dnia roboczego miesięcznie. Dla zobrazowania skali zmian na rysunku 4.5 przedstawiono porównanie średniego czasu przygotowania pakietu raportów przed i po wdrożeniu rozwiązań wspieranych przez AI.





Rysunek 4.5 Porównanie czasu przygotowania raportów przed i po wdrożeniu AI

Źródło: opracowanie własne na podstawie wywiadu eksperckiego.

Ekspert podkreślił jednak, że oszczędność ta nie oznaczała zmniejszenia zakresu pracy, lecz zmianę jej charakteru – mniej czasu poświęcano na techniczne przygotowanie danych, a więcej na analizę i interpretację wyników.

Jednym z najważniejszych wniosków z wywiadu jest podkreślenie roli jakości danych. Ekspert wyraźnie wskazał, że pierwsze próby wdrożenia AI ujawniły problemy związane z niespójnością definicji wskaźników, różnicami w klasyfikacji kosztów czy brakiem pełnej integracji danych operacyjnych z finansowymi. Dopiero uporządkowanie struktur danych oraz ich standaryzacja umożliwiły uzyskanie realnej wartości z zastosowanych modeli. W praktyce oznacza to, że technologia sama w sobie nie jest wystarczająca – kluczowe znaczenie ma fundament w postaci dobrze zarządzanych danych.

W zakresie korzyści ekspert wskazał przede wszystkim na oszczędność czasu oraz szybsze wykrywanie nieprawidłowości. AI pozwala szybciej identyfikować obszary wymagające uwagi, co ogranicza konieczność ręcznego przeglądania dużych zbiorów danych. Szczególnie widoczne efekty zaobserwowano w analizie odchyleń budżetowych. Wcześniej controllerzy ręcznie przeglądali wszystkie pozycje kosztowe, aby zidentyfikować istotne różnice względem planu. Obecnie system wspierany algorytmem wykrywania anomalii wskazuje pozycje odbiegające od trendu historycznego lub przyjętych progów istotności. W

rezultacie czas wstępnej identyfikacji obszarów wymagających analizy skrócił się z kilku godzin do kilkunastu minut, co znacząco usprawniło proces raportowania.

Wywiad dostarczył również istotnych informacji na temat postrzeganych ryzyk. Największym zagrożeniem, zdaniem rozmówcy, jest ryzyko błędnych wniosków wynikających ze słabej jakości danych wejściowych. Wskazano także na problem tzw. „czarnej skrzynki”, czyli trudności w pełnym wyjaśnieniu sposobu działania bardziej zaawansowanych modeli. W controllingu finansowym, gdzie istotne jest uzasadnienie prezentowanych wyników przed zarządem, brak przejrzystości algorytmu może ograniczać poziom zaufania do systemu. Dodatkowo zwrócono uwagę na ryzyko nadmiernego zaufania do wyników AI, szczególnie w warunkach presji czasu.

Istotnym wątkiem była również zmiana charakteru pracy controllera. Wdrożenie AI nie doprowadziło do redukcji etatów, lecz do wyraźnego przesunięcia akcentu z pracy manualnej na analizę i interpretację danych. Udział czynności technicznych związanych z przygotowaniem danych i raportów zmniejszył się – szacunkowo z około 50–60% czasu pracy do około 30–40%. Zespół controllingu poświęca obecnie więcej czasu na analizę przyczyn odchyłeń, rozmowy z menedżerami operacyjnymi oraz wsparcie decyzji biznesowych. Jednocześnie pojawiła się nowa odpowiedzialność związana z kontrolą jakości danych, monitorowaniem poprawności działania modeli oraz weryfikacją wyników generowanych przez systemy. Oznacza to, że choć część zadań została zautomatyzowana, rola controllera stała się bardziej analityczna i nadzorcza.

W obszarze barier wdrożeniowych ekspert wskazał przede wszystkim na niedobór kompetencji analitycznych oraz konieczność budowania świadomości w zespole. Technologia jako taka nie była największym wyzwaniem – większą trudność stanowiło przygotowanie pracowników do pracy z nowymi narzędziami oraz przełamanie obaw związanych z potencjalną zmianą roli zawodowej. Kluczowe okazało się stopniowe wdrażanie rozwiązań oraz jasne określenie zasad odpowiedzialności i kontroli wyników.

Analiza wywiadu pozwala stwierdzić, że praktyczne doświadczenia eksperta są w dużej mierze spójne z wynikami badania ankietowego. Zarówno w części ilościowej, jak i jakościowej podkreślano znaczenie jakości danych, oszczędność czasu oraz rolę AI jako narzędzia wspierającego, a nie zastępującego człowieka. Jednocześnie wywiad wnosi dodatkową głębię interpretacyjną, pokazując konkretne mechanizmy organizacyjne i procesowe towarzyszące wdrażaniu sztucznej inteligencji w controllingu finansowym.

Można zatem uznać, że w praktyce AI w controllingu finansowym stanowi przede wszystkim szansę na zwiększenie efektywności i poprawę jakości analiz, jednak jej skuteczne



wykorzystanie wymaga odpowiednich fundamentów danych, kompetencji zespołu oraz zachowania kontroli nad procesem decyzyjnym

#### 4.6 Synteza wyników i porównanie z literaturą

Celem niniejszego podrozdziału jest zestawienie wyników badań własnych – zarówno ankiety ilościowej, jak i wywiadu eksperckiego – z ustaleniami przedstawionymi w rozdziale trzecim, opartym na analizie literatury naukowej oraz raportów branżowych. Takie ujęcie pozwala ocenić, na ile obserwacje empiryczne potwierdzają tezy formułowane w opracowaniach teoretycznych oraz w jakich obszarach pojawiają się rozbieżności.

Pierwszym istotnym wnioskiem jest zgodność pomiędzy literaturą a wynikami badań w zakresie obszarów zastosowania AI w controllingu. W rozdziale trzecim wskazano, że największy potencjał wykorzystania AI dotyczy prognozowania, analizy odchyłeń oraz automatyzacji raportowania. Wyniki ankiety potwierdzają tę tendencję – respondenci najczęściej wskazywali właśnie te obszary jako miejsce praktycznego zastosowania AI. Podobnie ekspert w wywiadzie podkreślił, że największe efekty organizacja uzyskała w prognozowaniu kosztów oraz w identyfikowaniu nietypowych odchyłeń. Oznacza to, że praktyka rynkowa w Polsce jest spójna z kierunkami opisywanymi w literaturze międzynarodowej.

Drugim obszarem wyraźnej zbieżności jest postrzeganie korzyści. W literaturze wskazywano, że AI przyczynia się do skrócenia czasu analiz, poprawy trafności prognoz oraz zwiększenia wartości informacyjnej raportów controllingowych. Wyniki ankiety pokazują wyraźną przewagę średniej oceny korzyści nad ryzykami ( $M = 4,14$  vs  $M = 3,32$ ), co potwierdza, że AI jest postrzegana jako narzędzie wspierające efektywność pracy controllera. Ekspert również wskazał oszczędność czasu oraz szybsze wykrywanie nieprawidłowości jako kluczowe korzyści. Tym samym można uznać, że hipoteza główna pracy – mówiąca o wzroście efektywności analiz dzięki AI – znajduje potwierdzenie zarówno w badaniu ilościowym, jak i jakościowym.

Jednocześnie wyniki badań własnych potwierdzają wnioski literaturowe dotyczące znaczenia jakości danych. W rozdziale trzecim wielokrotnie podkreślano, że skuteczność modeli AI zależy od spójności i integracji danych. W wywiadzie ekspert wyraźnie zaznaczył, że bez uporządkowania struktur danych wdrożenie AI nie przynosi oczekiwanych rezultatów. W ankiecie natomiast obawy związane z jakością danych należały do najczęściej wskazywanych ryzyk. Choć analiza statystyczna nie wykazała istotnej korelacji między oceną jakości danych a etapem wdrożenia AI, to interpretacyjnie można stwierdzić, że jakość danych



stanowi kluczowy warunek efektywnego wykorzystania narzędzi AI – co jest w pełni zgodne z literaturą.

Kolejnym istotnym wątkiem jest problem wyjaśnialności modeli (efekt „czarnej skrzynki”) oraz potrzeba kontroli. W literaturze podkreślano znaczenie explainable AI (XAI) oraz konieczność utrzymania nadzoru nad algorytmami, zwłaszcza w finansach. Wyniki wywiadu wprost potwierdzają ten problem – ekspert wskazał, że trudność w wyjaśnieniu logiki modelu może ograniczać zaufanie do jego wyników. W badaniu ankietowym respondenci również zgadzali się ze stwierdzeniem, że wyjaśnienie działania modelu bywa problematyczne. Tym samym badania własne wzmacniają tezę, że rozwój AI w controllingu musi iść w parze z mechanizmami kontroli i odpowiedzialności.

W zakresie barier wdrożeniowych również widoczna jest spójność z literaturą. W opracowaniach branżowych wskazywano na znaczenie kompetencji cyfrowych, integracji systemów oraz zarządzania zmianą. Ankieta pokazała, że najczęściej wskazywanymi barierami są brak kompetencji w obszarze danych i AI oraz problemy z jakością danych. Wywiad potwierdził, że największym wyzwaniem nie była sama technologia, lecz przygotowanie zespołu oraz uporządkowanie danych. Można więc stwierdzić, że czynniki organizacyjne i kompetencyjne mają równie duże znaczenie jak aspekt techniczny wdrożenia.

Warto jednak zwrócić uwagę na jedną istotną obserwację: w analizie statystycznej nie stwierdzono istotnych zależności między wielkością organizacji czy formalizacją zasad AI a etapem wdrożenia. Literatura często sugeruje, że większe podmioty lub organizacje bardziej dojrzałe cyfrowo szybciej wdrażają AI. W badanej próbie zależność ta nie była jednoznaczna. Może to oznaczać, że w warunkach polskiego rynku również mniejsze lub średnie podmioty podejmują działania w kierunku wdrożenia AI, a proces adopcji technologii nie jest już wyłącznie domeną największych organizacji.

Ostatnim ważnym obszarem porównania jest zmiana roli controllera. W rozdziale trzecim wskazywano, że rozwój AI prowadzi do przesunięcia roli controllera z funkcji operacyjnej w stronę analityczno-doradczej. Wyniki wywiadu jednoznacznie potwierdzają tę tezę – ekspert podkreślił, że AI przejęła część zadań rutynowych, co umożliwiło większe zaangażowanie w analizę i współpracę z biznesem. W ankiecie respondenci wysoko oceniali stwierdzenie, że AI pozwala skupić się bardziej na pracy analitycznej niż na manualnym przygotowywaniu raportów. Oznacza to, że kierunek rozwoju roli controllera opisany w literaturze znajduje odzwierciedlenie w praktyce.

Podsumowując, wyniki badań własnych w dużej mierze potwierdzają ustalenia przedstawione w rozdziale trzecim. AI w controllingu finansowym jest postrzegana przede



wszystkim jako narzędzie zwiększające efektywność, szczególnie w obszarze prognozowania i analizy odchyleń. Jednocześnie jej skuteczne wykorzystanie wymaga odpowiedniej jakości danych, rozwiniętych kompetencji analitycznych oraz zachowania kontroli nad procesem decyzyjnym. Badania empiryczne pokazują, że rozwój AI w controllingu ma charakter ewolucyjny – nie polega na zastąpieniu controllera, lecz na transformacji jego roli w kierunku partnera biznesowego pracującego w środowisku zaawansowanej analityki danych.



## ROZDZIAŁ 5. WNIOSKI I REKOMENDACJE DOTYCZĄCE WDRAŻANIA AI W CONTROLLINGU

### 5.1 Podsumowanie wyników pracy

Celem niniejszej pracy była analiza możliwości, ograniczeń oraz kierunków rozwoju zastosowania sztucznej inteligencji w controllingu finansowym. Przeprowadzone rozważania teoretyczne oraz badania empiryczne pozwoliły na kompleksowe spojrzenie na to zagadnienie – zarówno z perspektywy literatury i raportów branżowych, jak i praktyki funkcjonowania przedsiębiorstw działających w Polsce.

Część teoretyczna wykazała, że controlling finansowy w ostatnich latach podlega dynamicznej transformacji. Rosnąca ilość danych, rozwój narzędzi analitycznych oraz postępująca cyfryzacja procesów biznesowych powodują, że rola controllera stopniowo ewoluuje – od funkcji skoncentrowanej głównie na raportowaniu i kontroli w stronę funkcji analityczno-doradczej, silniej powiązanej ze wsparciem decyzji menedżerskich. W literaturze podkreślano, że sztuczna inteligencja może odegrać istotną rolę w tej zmianie, zwłaszcza w obszarach prognozowania, analizy odchyleń, zarządzania ryzykiem oraz automatyzacji raportowania.

Wyniki badań empirycznych potwierdzają, że wykorzystanie AI w controllingu finansowym nie jest już wyłącznie koncepcją teoretyczną, lecz realnym elementem funkcjonowania wielu organizacji. Znaczna część badanych przedsiębiorstw wykorzystuje rozwiązania oparte na AI w sposób produkcyjny lub znajduje się na etapie pilotażu. Najczęściej wskazywane obszary zastosowania – prognozowanie, analiza odchyleń oraz wsparcie raportowania – są zgodne z kierunkami opisanymi w literaturze. Można więc stwierdzić, że praktyka rynkowa podąża w tym samym kierunku, który od kilku lat akcentują opracowania naukowe i branżowe.

Analiza wyników ankiety wykazała wyraźną przewagę postrzeganych korzyści nad ryzykami związanymi z wykorzystaniem AI. Respondenci wysoko ocenili wpływ sztucznej inteligencji na skrócenie czasu przygotowania raportów, poprawę trafności prognoz oraz możliwość skoncentrowania się na pracy analitycznej zamiast na czynnościach manualnych. Jednocześnie zauważalne są obawy dotyczące jakości danych, trudności w wyjaśnieniu działania modeli oraz ryzyka nadmiernego zaufania do wyników generowanych przez systemy. Oznacza to, że AI jest postrzegana jako realne wsparcie, ale nie jako rozwiązanie pozbawione zagrożeń.

Wywiad ekspercki w istotny sposób pogłębił wnioski płynące z badania ilościowego. Z perspektywy praktyka kluczowym warunkiem skutecznego wdrożenia AI jest uporządkowanie



danych oraz jasne określenie zasad odpowiedzialności za wyniki modeli. Ekspert podkreślił, że technologia sama w sobie nie stanowi największego wyzwania – większym problemem bywa przygotowanie organizacji, standaryzacja danych oraz budowanie kompetencji w zespole. Jednocześnie wskazano, że AI nie zastępuje controllera, lecz zmienia charakter jego pracy, przesuując akcent z czynności operacyjnych w stronę analizy, interpretacji danych oraz współpracy z biznesem.

Na podstawie przeprowadzonych badań można uznać, że hipoteza główna pracy została potwierdzona – zastosowanie sztucznej inteligencji w controllingu finansowym przyczynia się do zwiększenia efektywności analiz oraz wspiera proces podejmowania decyzji. Potwierdzenie znalazły również hipotezy szczegółowe dotyczące potencjału AI w obszarze analizy predykcyjnej i automatyzacji raportowania, a także te wskazujące na istotne bariery wdrożeniowe związane z kompetencjami i jakością danych.

Całościowo można stwierdzić, że sztuczna inteligencja w controllingu finansowym stanowi przede wszystkim szansę rozwojową. Jej skuteczne wykorzystanie nie polega jednak na bezrefleksyjnej automatyzacji procesów, lecz na świadomym połączeniu technologii z wiedzą ekspercką, kontrolą jakości danych oraz odpowiedzialnym zarządzaniem ryzykiem. AI nie eliminuje potrzeby kompetencji finansowych, lecz wręcz zwiększa znaczenie roli controllera jako osoby interpretującej wyniki i nadającej im kontekst biznesowy.

W świetle uzyskanych wyników można uznać, że rozwój sztucznej inteligencji w controllingu ma charakter ewolucyjny – nie prowadzi do zastąpienia specjalistów, lecz do redefinicji ich roli w kierunku bardziej strategicznym i analitycznym. W kolejnych podrozdziałach zostaną przedstawione szczegółowe wnioski dotyczące korzyści, ryzyk oraz rekomendacji wdrożeniowych wynikających z przeprowadzonych analiz.

## **5.2 Ocena korzyści i ryzyk wdrożenia AI**

Ocena korzyści i ryzyk związanych z wdrożeniem sztucznej inteligencji w controllingu finansowym stanowi kluczowy element niniejszej pracy, ponieważ pozwala spojrzeć na AI nie tylko jako na rozwiązanie technologiczne, lecz jako na narzędzie wpływające na sposób funkcjonowania całej organizacji. Zarówno literatura przedmiotu, jak i wyniki badań własnych wskazują, że bilans ten ma charakter złożony, choć w badanej próbie przeważają oceny pozytywne.

Najbardziej wyraźną korzyścią wynikającą z zastosowania AI jest wzrost efektywności pracy controllingu. Respondenci badania ankietowego wysoko ocenili wpływ AI na skrócenie czasu przygotowania raportów oraz możliwość szybszego wykrywania odchyleń. W praktyce



oznacza to ograniczenie czasu poświęcanego na czynności manualne i powtarzalne, takie jak agregacja danych czy wstępne przeglądanie zestawień. Z perspektywy organizacyjnej pozwala to przesunąć zasoby w stronę analizy i interpretacji wyników, a więc działań o większej wartości dodanej.

Drugą istotną korzyścią jest poprawa jakości prognoz i analiz predykcyjnych. Zastosowanie modeli opartych na danych historycznych umożliwia identyfikację trendów oraz zależności, które w klasycznych analizach mogłyby zostać pominięte. W badaniu ankietowym respondenci wskazywali, że AI wspiera trafność prognoz finansowych, szczególnie w obszarach stabilnych i powtarzalnych. Wywiad ekspercki potwierdził, że w takich warunkach modele mogą skutecznie wspierać controllerów w planowaniu i analizie scenariuszy.

Kolejną korzyścią jest uporządkowanie procesów raportowania oraz standaryzacja analiz. Automatyzacja wybranych etapów pracy wymusza często większą spójność danych, jasne definicje wskaźników oraz określenie odpowiedzialności za poszczególne elementy procesu. W dłuższej perspektywie może to prowadzić do podniesienia ogólnej jakości systemu informacji zarządczej w przedsiębiorstwie.

Jednocześnie wdrożenie AI wiąże się z istotnymi ryzykami, które nie mogą być pomijane. Najczęściej wskazywanym zagrożeniem – zarówno w badaniu ankietowym, jak i w wywiadzie – jest problem jakości danych. Modele AI opierają się na danych wejściowych, dlatego ich skuteczność bezpośrednio zależy od spójności, kompletności i poprawności informacji. W przypadku niespójnych definicji wskaźników lub błędów w danych istnieje ryzyko generowania błędnych wniosków, które mogą prowadzić do nieoptymalnych decyzji.

Drugim istotnym ryzykiem jest ograniczona przejrzystość działania bardziej zaawansowanych modeli, określana jako efekt „czarnej skrzynki”. W controllingu finansowym, gdzie konieczne jest uzasadnienie wyników przed zarządem lub audytorem, brak możliwości pełnego wyjaśnienia logiki modelu może budzić wątpliwości i obniżać poziom zaufania do systemu. Z tego względu kluczowe staje się łączenie rozwiązań technologicznych z odpowiednimi mechanizmami nadzoru oraz weryfikacji wyników.

Kolejnym zagrożeniem jest ryzyko nadmiernego zaufania do wyników generowanych przez AI. W warunkach presji czasu i dużej liczby obowiązków istnieje pokusa traktowania rekomendacji systemu jako ostatecznych. Może to prowadzić do ograniczenia krytycznej analizy oraz pomijania kontekstu biznesowego, który nie zawsze jest uwzględniany w modelu. Zarówno literatura, jak i wywiad ekspercki podkreślają, że AI powinna być traktowana jako narzędzie wspierające, a nie zastępujące człowieka w procesie decyzyjnym.



Do ryzyk o charakterze organizacyjnym należy również niedobór kompetencji analitycznych i technologicznych w zespołach controllingu. Wdrożenie AI wymaga nie tylko znajomości narzędzi, lecz także umiejętności interpretacji wyników oraz zrozumienia ograniczeń modeli. Brak takich kompetencji może prowadzić do nieefektywnego wykorzystania technologii lub błędnej interpretacji rezultatów.

Podsumowując, analiza korzyści i ryzyk wskazuje, że sztuczna inteligencja w controllingu finansowym przynosi realne i mierzalne efekty w postaci wzrostu efektywności, poprawy jakości analiz oraz lepszego wsparcia decyzji menedżerskich. Jednocześnie jej wdrożenie wymaga świadomego zarządzania ryzykiem, dbałości o jakość danych, zachowania kontroli nad procesem analitycznym oraz inwestycji w rozwój kompetencji zespołu. Bilans wdrożenia AI można więc określić jako pozytywny, pod warunkiem że technologia jest traktowana jako element systemu zarządzania, a nie autonomiczne rozwiązanie zastępujące wiedzę ekspercką.

### **5.3 Rekomendacje dla przedsiębiorstw dotyczące wdrażania AI w controllingu finansowym**

Na podstawie przeprowadzonych analiz teoretycznych oraz wyników badań empirycznych można sformułować kilka praktycznych rekomendacji dla przedsiębiorstw planujących wdrożenie rozwiązań opartych na sztucznej inteligencji w controllingu finansowym. Rekomendacje te wynikają zarówno z obserwowanych korzyści, jak i zidentyfikowanych barier oraz ryzyk.

Pierwszą i najważniejszą rekomendacją jest rozpoczęcie procesu wdrożeniowego od uporządkowania danych. Zarówno literatura, jak i wyniki wywiadu eksperckiego jednoznacznie wskazują, że jakość danych stanowi fundament skutecznego wykorzystania AI. Przed wdrożeniem modeli predykcyjnych lub narzędzi generatywnych organizacja powinna przeanalizować spójność definicji wskaźników, sposób klasyfikacji kosztów, strukturę danych w systemach ERP oraz poziom integracji danych operacyjnych z finansowymi. Bez tego nawet najbardziej zaawansowane narzędzie nie przyniesie oczekiwanych rezultatów.

Drugą rekomendacją jest wdrażanie AI stopniowo, w oparciu o jasno określone cele biznesowe. Zamiast próbować automatyzować wiele procesów jednocześnie, warto rozpocząć od jednego, konkretnego obszaru – na przykład prognozowania wybranej kategorii kosztów lub analizy odchyleń budżetowych. Pozwala to ograniczyć ryzyko projektowe, szybciej ocenić efekty wdrożenia oraz zbudować w organizacji zaufanie do nowych narzędzi. Podejście



etapowe umożliwia również lepsze dostosowanie modelu do specyfiki firmy oraz bieżące korygowanie błędów.

Trzecim istotnym elementem jest zapewnienie mechanizmów kontroli i nadzoru nad działaniem modeli. AI w controllingu nie powinna funkcjonować jako autonomiczny system decyzyjny. Niezbędne jest określenie odpowiedzialności za interpretację wyników, regularna weryfikacja działania modeli oraz porównywanie ich rezultatów z klasycznymi metodami analizy. W praktyce oznacza to wprowadzenie procedur walidacyjnych, okresowych przeglądów modeli oraz jasnych zasad korzystania z narzędzi generatywnych.

Czwartą rekomendacją jest inwestowanie w rozwój kompetencji zespołu controllingu. Wdrożenie AI nie oznacza konieczności przekształcenia controllerów w programistów, jednak wymaga podstawowego rozumienia logiki działania modeli, świadomości ich ograniczeń oraz umiejętności krytycznej analizy wyników. Organizacje powinny wspierać rozwój kompetencji analitycznych, pracy z danymi oraz umiejętności interpretacji informacji generowanych przez systemy. Równie istotne są kompetencje komunikacyjne, pozwalające wyjaśniać wyniki AI osobom nietechnicznym.

Kolejną rekomendacją jest zapewnienie wsparcia zarządu i odpowiedniego zarządzania zmianą. Wdrożenie AI często wiąże się z obawami pracowników dotyczącymi zmiany charakteru pracy lub utraty kontroli nad procesami. Jasna komunikacja celu projektu, podkreślenie roli AI jako narzędzia wspierającego, a nie zastępującego człowieka, oraz włączenie zespołu w proces wdrożeniowy zwiększają szanse na akceptację i efektywne wykorzystanie technologii.

Warto również zwrócić uwagę na aspekt etyczny i regulacyjny. Przedsiębiorstwa powinny opracować wewnętrzne wytyczne dotyczące wykorzystania AI, określające m.in. zasady ochrony danych, zakres odpowiedzialności użytkowników oraz sposób dokumentowania decyzji wspieranych przez modele. Takie podejście zwiększa przejrzystość procesu i ogranicza ryzyko związane z niewłaściwym użyciem narzędzi.

Podsumowując, skuteczne wdrożenie AI w controllingu finansowym wymaga kompleksowego podejścia obejmującego jakość danych, jasno określone cele biznesowe, mechanizmy kontroli, rozwój kompetencji oraz odpowiedzialne zarządzanie zmianą. Technologia sama w sobie nie stanowi gwarancji sukcesu – kluczowe jest jej właściwe osadzenie w strukturze organizacyjnej i procesach zarządczych. Przedsiębiorstwa, które podejdu do wdrożenia w sposób strategiczny i przemyślany, mogą realnie zwiększyć efektywność controllingu oraz wzmocnić jego rolę jako partnera biznesowego.



## 5.4 Perspektywy i kierunki dalszego rozwoju

Rozwój sztucznej inteligencji w controllingu finansowym należy postrzegać jako proces dynamiczny, który będzie w kolejnych latach nabierał znaczenia wraz z postępującą cyfryzacją przedsiębiorstw. Zarówno literatura, jak i wyniki badań własnych wskazują, że AI nie stanowi chwilowego trendu, lecz element szerszej transformacji sposobu zarządzania informacją finansową.

W perspektywie najbliższych lat można oczekiwać dalszego wzrostu znaczenia analityki predykcyjnej w controllingu. Prognozowanie oparte na modelach uczących się na danych historycznych będzie coraz częściej integrowane z danymi operacyjnymi oraz zewnętrznymi (np. makroekonomicznymi), co może zwiększać trafność planów i budżetów. Możliwe jest również szersze wykorzystanie analiz scenariuszowych wspieranych przez AI, szczególnie w warunkach niepewności gospodarczej i zmienności otoczenia rynkowego.

Kolejnym kierunkiem rozwoju będzie integracja narzędzi generatywnej AI z procesami raportowania zarządczego. Już obecnie systemy te wspierają przygotowywanie wstępnych komentarzy do raportów czy podsumowań danych. W przyszłości można spodziewać się większej personalizacji raportów oraz automatycznego dostosowywania ich treści do potrzeb konkretnych odbiorców. Równocześnie wzrośnie znaczenie mechanizmów kontroli i weryfikacji treści generowanych przez modele językowe.

Istotnym obszarem będzie również rozwój koncepcji explainable AI, czyli modeli umożliwiających wyjaśnienie logiki działania algorytmu. W controllingu finansowym, gdzie decyzje muszą być uzasadnione i transparentne, wyjaśnialność modeli stanie się jednym z kluczowych kryteriów ich wyboru i oceny. Można przypuszczać, że organizacje będą preferowały rozwiązania, które pozwalają na interpretację wpływu poszczególnych zmiennych na wynik modelu.

W kontekście kompetencyjnym rola controllera będzie ulegać dalszej transformacji. Wraz z automatyzacją części zadań operacyjnych zwiększy się zapotrzebowanie na umiejętności analityczne, interpretacyjne oraz komunikacyjne. Controller przyszłości będzie coraz częściej pełnił funkcję integratora informacji – łączącego dane finansowe, operacyjne i technologiczne oraz tłumaczącego wyniki analiz na język decyzji biznesowych.

Można więc stwierdzić, że kierunek rozwoju controllingu finansowego zmierza w stronę większej integracji technologii i wiedzy eksperckiej. AI nie zastąpi controllera, lecz będzie coraz silniej wspierać jego pracę, zwłaszcza w obszarach wymagających analizy dużych zbiorów danych oraz szybkiego reagowania na zmiany.



## 5.5 Ograniczenia badań i propozycje przyszłych prac

Przeprowadzone badania empiryczne, mimo że pozwoliły na sformułowanie istotnych wniosków, posiadają pewne ograniczenia, które należy uwzględnić przy interpretacji wyników.

Po pierwsze, badanie ankietowe miało charakter nielosowy i opierało się na doborze celowym respondentów. Oznacza to, że próba nie jest w pełni reprezentatywna dla wszystkich przedsiębiorstw działających w Polsce. Wyniki należy więc interpretować jako obraz tendencji i opinii w badanej grupie, a nie jako uniwersalne odzwierciedlenie całego rynku.

Po drugie, dane ankietowe mają charakter samoopisowy. Respondenci oceniali poziom wykorzystania AI, jakość danych czy skalę korzyści na podstawie własnych doświadczeń i percepcji. Tego typu dane mogą być obciążone subiektywizmem, choć jednocześnie stanowią cenne źródło informacji o postawach i nastawieniu praktyków.

Po trzecie, część jakościowa badania opierała się na jednym wywiadzie eksperckim. Choć rozmowa dostarczyła pogłębionych informacji i pozwoliła lepiej zinterpretować wyniki ankiety, liczba wywiadów mogłaby zostać zwiększona w przyszłych badaniach, aby uzyskać szerszą perspektywę, np. z różnych branż lub typów organizacji.

W przyszłości warto byłoby rozszerzyć badania o analizę porównawczą między sektorami (np. produkcja vs. SSC/GBS vs. sektor finansowy), a także zbadać zależności między poziomem dojrzałości danych a realnymi efektami wdrożeń AI. Interesującym kierunkiem dalszych prac mogłoby być również badanie wpływu AI na wyniki finansowe przedsiębiorstw w ujęciu ilościowym, np. poprzez analizę wskaźników efektywności przed i po wdrożeniu.

Podsumowując, mimo wskazanych ograniczeń, przeprowadzone badania pozwoliły na realizację celu pracy i sformułowanie wniosków dotyczących aktualnego stanu wykorzystania sztucznej inteligencji w controllingu finansowym. Stanowią one punkt wyjścia do dalszych analiz nad rolą AI w zarządzaniu finansami przedsiębiorstw oraz ewolucją funkcji controllingu w warunkach postępującej cyfryzacji.

## BIBLIOGRAFIA

- Aghion, P., Jones, B. F., & Jones, C. I. (2017, October). Artificial Intelligence and Economic Growth. *NBER Working Paper 23928*. doi:10.3386/w23928
- Agrawal, A., Gans, J. i Goldfarb, A. (2018). Prediction Machines: The Simple Economics of Artificial Intelligence. *Harvard Business Review Press*. Pobrano z lokalizacji <https://hbr.org/product/prediction-machines-the-simple-economics-of-artificial-intelligence/10108-HBK-ENG>
- Anggun, D. P., Sariwulan, R. M., & Husein, A. (2023). *Artificial Intelligence in Society*.
- Appelbaum, D., Kogan, A., & Vasarhelyi, M. A. (2017). Big Data and Analytics in the Modern Audit Engagement. *Accounting Horizons*(31(3)), pp. 1-20.
- Ayari, H., Guetari, R., & Kraïem, N. (2026). Machine learning powered financial credit scoring: a systematic literature review. *Artificial Intelligence Review*. Retrieved from <https://doi.org/10.1007/s10462-025-11416-2>
- Barocas, S., & Selbst, A. D. (2016). Big Data's Disparate Impact. *California Law Review*(104(3)). Retrieved from <https://www.cs.yale.edu/homes/jf/BarocasSelbst.pdf>
- Bednarek, P. (2023, October 9–11). XXVII Conference on Accounting and Controlling Challenges of contemporary accounting and controlling held in Polanica-Zdrój. *48(1)*, pp. 187-192. Retrieved from <https://doi.org/10.5604/01.3001.0054.4093>
- Begenau, J., Farboodi, M., & Veldkamp, L. (2018). Big Data in Finance. *Review of Financial Studies*( 31(12)).
- Bercz, N. (2022). Zastosowanie modelowania matematycznego i uczenia maszynowego w zarządzaniu ryzykiem kredytowym w bankach i instytucjach finansowych. In H. Dudycz (Ed.), *Informatyka w biznesie*. Wrocław: Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu. Retrieved from <https://www.dbc.wroc.pl/dlibra/publication/156882/edition/118534/content>
- Bielawski, R. (2025). *Współczesny controlling – nowe wyzwania* (Tom nr 31(7)). „Zeszyty Naukowe Akademii Górnośląskiej”. Pobrano z lokalizacji [https://www.gwsh.pl/content/biblioteka/org/zeszyty/ag/zn31/ZN31AG\\_01Bielawski.pdf](https://www.gwsh.pl/content/biblioteka/org/zeszyty/ag/zn31/ZN31AG_01Bielawski.pdf)
- Binz, O., Schipper, K., & Standridge, K. R. (2025). Estimating profitability decomposition frameworks via machine learning: Implications for earnings forecasting and financial statement analysis. *Journal of Accounting and Economics*, 80. Retrieved from <https://doi.org/10.1016/j.jacceco.2025.101805>
- Brynjolfsson, E., & McAfee, A. (2014). *The Second Machine Age*. New York .
- Cao, L. (2020, August). AI in Finance: A Review. *Preprint*.



- Cao, S. S., Jiang, W., Lei, L. G., & Zhou, Q. C. (2024). Applied AI for finance and accounting: Alternative data and opportunities. *Pacific-Basin Finance Journal*. doi:10.1016
- Czyżewski, P., & Karwowski, M. (2025, czerwiec). Wyzwania związane z wykorzystaniem nowoczesnych technologii sztucznej inteligencji (AI) w rachunkowości i podatkach. *Kwartalnik Nauk O Przedsiębiorstwie*, 76(2), pp. 41–57. Retrieved from <https://doi.org/10.33119/KNOP.2025.76.2.3>
- Davenport, T. H., & Kirby, J. (2015). Beyond Automation. *Harvard Business Review*. Retrieved from <https://hbr.org/2015/06/man-machine-and-work>
- Domingos, P. (2015). *The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World*. New York.
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. Retrieved from <https://arxiv.org/pdf/1702.08608>
- Dyczkowski, T. (2024). *Wyzwania implementacji controllingu w praktyce gospodarczej*. Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu. Retrieved from <https://books.google.pl/books?id=e1NJEQAAQBAJ>
- Eisfeldt, A. L., & Schubert, G. (2024, October). AI and Finance. *NBER Working Paper 33076*. doi:10.3386/w33076
- Eksperci Grupy Roboczej ds. Sztucznej Inteligencji. (2022). *Rekomendacje w zakresie sztucznej inteligencji w sektorze finansowym, Komisja Nadzoru Finansowego*. Warszawa.
- Ghai, D., Rawal, K., Dhir, K., & Tripathi, S. L. (2024). *Artificial Intelligence Techniques for Sustainable Development*. CRC Press. Retrieved from <https://books.google.pl/books?id=0a8vEQAAQBAJ>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*( 349(6245)). Retrieved from <https://science.sciencemag.org/content/349/6245/255>
- Kaszuba-Perz, A., & Perz, P. (2008). *Metody pomiaru ryzyka rynkowego w systemie controllingu*, „Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu” (Vol. 15). Retrieved from [https://dlibra.kdm.wcss.pl/Content/125055/Kaszuba-Perz\\_Perz\\_Metody\\_pomiaru\\_ryzyka.pdf](https://dlibra.kdm.wcss.pl/Content/125055/Kaszuba-Perz_Perz_Metody_pomiaru_ryzyka.pdf)
- Kokina, J., & Davenport, T. H. (2017). The Emergence of Artificial Intelligence in Accounting. *Journal of Emerging Technologies in Accounting*, 1(14), pp. 115–122.
- Komisja Europejska. (2021). *ROZPORZĄDZENIE PARLAMENTU EUROPEJSKIEGO I RADY USTANAWIAJĄCE ZHARMONIZOWANE PRZEPISY DOTYCZĄCE*



*SZTUCZNEJ INTELIGENCJI (AKT W SPRAWIE SZTUCZNEJ INTELIGENCJI) I ZMIENIAJĄCE NIEKTÓRE AKTY USTAWODAWCZE UNII.* Bruksela.

- Kondort, G., & Cioc, R. (2024). Types of AI and Their Suitability for Performing Daily Activities. *Proceedings of the 18th International Conference on Business Excellence*, pp. 2283–2285. doi:10.2478/picbe-2024-0192
- Krajewska, A. (2024). Sztuczna inteligencja – zagrożenie czy szansa? *Społeczeństwo*( 1 (165)), pp. 78-90.
- Krakowska, W., & Bagińska, A. (2025). *Znaczenie kontrolera finansowego w zarządzaniu wizerunkiem przedsiębiorstwa* (Vol. 9(2)). doi:10.24427/az-2025-0024
- Krystian, M., & Zaskórski, P. (2023). Sztuczna inteligencja w usprawnianiu procesów biznesowych. *Nowoczesne Systemy Zarządzania*(4), pp. 135-152.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE*(13(3)). Retrieved from <https://doi.org/10.1371/journal.pone.0194889>
- Manuylenko, V. V., & Shebzukhova, M. A. (2021). *Theory for Financial Controlling in Corporations in the Modern Environment*, „*Universal Journal of Accounting and Finance*” (Vols. Vol. 9, No. 4). Retrieved from [https://www.academia.edu/61265529/Theory\\_for\\_Financial\\_Controlling\\_in\\_Corporations\\_in\\_the\\_Modern\\_Environment](https://www.academia.edu/61265529/Theory_for_Financial_Controlling_in_Corporations_in_the_Modern_Environment)
- Nesterak. (2025). Technologie cyfrowe jako czynnik zmian rynku pracy w sektorze GBS. In P. Chlipała, A. Niemczyk, & Z. Gródek-Szostak (Eds.). Kraków: Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie.
- Nesterak, J., Jabłoński, M., & Kowalski, M. J. (2020). *Controlling procesów w praktyce przedsiębiorstw działających w Polsce*. (M. Jędrzejczyk, Ed.) Kraków: Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie.
- Nissim, D., & Penman, S. H. (2003). Financial statement analysis of leverage and how it informs about profitability and price-to-book ratios. *Review of Accounting Studies*, 8(4), pp. 531–560. Retrieved from <https://doi.org/10.1023/A:1027326515669>
- Pypłacz, P., & Sasak, J. (2022). RPA jako narzędzie automatyzacji i optymalizacji procesów. *Organizacja i Kierowanie*(2 (191)), pp. 173-188. Retrieved from <https://www.ceeol.com/search/article-detail?id=1073495>
- Radziszowska, M., & Sobolevska, N. (2024). Nowe wyzwania i możliwości: rola sztucznej inteligencji w świecie rachunkowości i finansów. In E. Śnieżek, & J. Piłacik (Eds.), *Rachunkowość w nurcie wyzwań współczesnego biznesu* (p. 9). Wydawnictwo SIZ.
- Ribeiro, J., Lima, R., Eckhardt, T., & Paiva, S. (2021). Robotic Process Automation and Artificial Intelligence in Industry 4.0 – A Literature Review. *Procedia Computer*



- Science*, 181, pp. 51-58. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1877050921001393>
- Richins , G., Stapleton, A., Stratopoulos, T. C., & Wong, C. (2017, September). Big Data Analytics: Opportunity or Threat for the Accounting Profession? *Journal of Information Systems*, 3(31), pp. 63–79. Retrieved from <https://publications.aaahq.org/jis/article-abstract/31/3/63/1114/Big-Data-Analytics-Opportunity-or-Threat-for-the>
- Robaczyński, W. (2022, listopad–grudzień). Sztuczna inteligencja jako przedmiot kontroli . *Kontrola i Audyt*(6), pp. 9–10.
- Różanowski, K. (2007, 2). Sztuczna inteligencja: rozwój, szanse i zagrożenia. *Zeszyty Naukowe*, pp. 110–112. doi:10.26348/znwwsi.2.109
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach*, Pearson, Harlow. Retrieved from <https://www.pearson.com/en-us/subject-catalog/p/artificial-intelligence-a-modern-approach/P200000003500>
- Sadowska, B., & Waśniewski, P. (2020). *Sprawozdanie z forum Controlling – kształtowanie przyszłości* (Vol. 106(162)). *Zeszyty Teoretyczne Rachunkowości*. Retrieved from <https://ztr.skwp.pl/article/139007/pl>
- Salahudin, S., Sihidi, T., Karida, K., & Firdaus, M. (2024). Digital Budgeting Transformation and Future Challenges: A Bibliometric Analysis. *Journal of Governance and Public Policy*, 11(3). Retrieved from <https://doi.org/10.18196/jgpp.v11i3.21182>
- Shmueli, G. (2010). To Explain or to Predict? *Statistical Science*, 3(25). doi:10.1214/10-STS330
- Sierpińska-Sawicz, A. (2015). *Zadania i miejsce komórki controllingu w przedsiębiorstwie. Zeszyty Naukowe SGGW. Ekonomika i Organizacja Gospodarki Żywnościowej* (Vol. nr 112). Retrieved from <https://doi.org/10.22630/EIOGZ.2015.112.53>
- Singh, V., Choubey, B., & Sauer, S. (2024). Liquidity forecasting at corporate and subsidiary levels using machine learning. *Intelligent Systems in Accounting, Finance and Management*. Retrieved from <https://doi.org/10.1002/isaf.1565>
- Stylec-Szromek, P. (2018). Sztuczna inteligencja – prawo, odpowiedzialność, etyka. *Zeszyty Naukowe Politechniki Śląskiej. Organizacja i Zarządzanie*, z. 123, pp. 501-509. doi:10.29119/1641-3466.2018.123.34
- Supervision, Basel Committee on Banking. (2018, February). Sound Practices: implications of fintech developments for banks and bank supervisors.
- Sutton, S. G., Holt, M., & Arnold, V. (2016). Artificial intelligence research in accounting. *International Journal of Accounting Information Systems*(22).
- Sypniewska, B. A., & Gołębiowski, G. (2023). Sztuczna inteligencja — dylematy etyczne. *Przegląd Organizacji*(3(998)), pp. 248–254. doi:10.33141/po.2023.03.26



- Szafranowicz, M. (2025). Kompetencje menedżerów a sztuczna inteligencja – analiza trendów w literaturze naukowej i zainteresowaniach internautów. *Przegląd Organizacji*(2), pp. 16-18.
- Walicka, M., & Czemieli-Grzybowska, W. (2023). Sztuczna inteligencja w zarządzaniu kapitałem przedsiębiorstwa w dobie Przemysłu 5.0. *Akademia Zarządzania* , 4(7). doi:10.24427/az-2023-0058
- Wasserbacher, H., & Spindler, M. (2022). Machine learning for financial forecasting, planning and analysis: recent developments and pitfalls. *Digital Finance*(4), pp. 63-88. doi:10.1007/s42521-021-00046-2
- Zhang, N., & Liu, B. (2019). Alignment of Business in Robotic Process Automation,. *International Journal of Crowd Science*, 3(1), pp. 26-35. Retrieved from <https://doi.org/10.1108/IJCS-09-2018-0018>



## **Spis rysunków:**

Rysunek 4.1 Etap wykorzystania AI w organizacjach

Rysunek 4.2 Częstotliwość korzystania z narzędzi AI w pracy

Rysunek 4.3 Średnia ocena jakości danych w zależności od etapu wykorzystania AI

Rysunek 4.4 Porównanie średniej oceny korzyści i ryzyk związanych z AI

Rysunek 4.5 Porównanie czasu przygotowania raportów przed i po wdrożeniu AI



## Załączniki:

### Załącznik 1. Ankieta do pracy: „Wykorzystanie AI w controllingu finansowym - szanse, zagrożenia i kierunki rozwoju”

#### Instrukcja dla respondentów

Badanie jest anonimowe i służy wyłącznie celom naukowym (praca magisterska). Dotyczy wykorzystania rozwiązań opartych na sztucznej inteligencji (AI) w finansach i controllingu. W ankiecie przez „AI” rozumiemy m.in. uczenie maszynowe, generatywną AI (np. chatboty), inteligentną automatyzację oraz rozwiązania analityczne wykorzystujące algorytmy predykcyjne.

#### Sekcja A. Metryczka

##### A1. Stanowisko (jednokrotny wybór)

1. Controller finansowy / Specjalista ds. controllingu
2. Analityk finansowy / FP&A
3. Księgowość / Główna księgowa / Rachunkowość
4. Menedżer/Kierownik finansów / CFO
5. IT / Analityk danych / BI (w finansach)
6. Inne (jakie?) \_\_\_\_\_

##### A2. Staż pracy w obszarze finansów/controllingu

1. < 1 roku 2) 1–3 lata 3) 4–7 lat 4) 8–12 lat 5) > 12 lat

##### A3. Wielkość firmy (zatrudnienie)

1. 1–49 2) 50–249 3) 250–999 4) 1000+

##### A4. Branża (główna)

1. Produkcja 2) Handel 3) Usługi 4) Finanse/ubezpieczenia 5) IT/telekom 6) SSC/GBS 7)

Inna: \_\_\_\_\_

##### A5. Kapitał / zasięg

1. Polska firma 2) Międzynarodowa (oddział/centrala) 3) Nie wiem



A6. Czy Twoja organizacja ma wyodrębniony controlling?

1. Tak, dział controllingu
- 2) Tak, pojedyncza funkcja
- 3) Nie
- 4) Nie wiem

### **Sekcja B. Dojrzałość danych i narzędzi**

B1. Jak oceniasz jakość danych finansowych w Twojej organizacji? (Likert 1- 5)

1 - bardzo niska, 5 - bardzo wysoka

B2. Na ile dane są zintegrowane (ERP/CRM/BI/hurtownia danych)? (1- 5)

B3. Jakich narzędzi używasz w controllingu? (wielokrotny wybór)

- Excel / arkusze
- ERP (np. SAP/Oracle/Dynamics/inne)
- BI (Power BI / Tableau / Qlik / inne)
- Dedykowane narzędzia do budżetowania/planowania (np. Anaplan, Jedox, Tagetik, Adaptive, inne)
- RPA (np. UiPath/Power Automate/Blue Prism)
- Narzędzia AI/ML (modele predykcyjne, klasyfikacja, anomaly detection)
- Generatywna AI (np. ChatGPT, Copilot lub firmowe asystenty)
- Inne: \_\_\_\_

B4. Czy w firmie są formalne zasady dot. użycia AI (polityka/wytyczne)?

1. Tak
- 2) W przygotowaniu
- 3) Nie
- 4) Nie wiem

### **Sekcja C. Wykorzystanie AI w controllingu**

C1. Czy w Twojej organizacji wykorzystuje się AI w obszarze finansów/controllingu?

1. Tak, produkcyjnie (na stałe)
2. Tak, pilotaż / testy
3. Nie, ale planujemy w 12 mies.
4. Nie i nie planujemy
5. Nie wiem

C2. Jeśli „tak” lub „pilotaż”: w jakich obszarach? (wielokrotny wybór)



- Prognozowanie (przychody/koszty/cash flow)
- Planowanie i budżetowanie (scenariusze, rolling forecast)
- Analiza odchyleń (automatyczne wyjaśnienia/anomalie)
- Raportowanie zarządcze (generowanie komentarzy, podsumowań)
- Controlling kosztów (klasyfikacja kosztów, czynniki kosztotwórcze)
- Monitoring należności/ryzyka opóźnień
- Wykrywanie błędów i anomalii w danych
- Automatyzacja procesów (np. pobieranie/łączenie danych, uzgodnienia)
- Inne: \_\_\_\_

C3. Jak często korzystasz z narzędzi AI w pracy?

1. Codziennie 2) Kilka razy w tygodniu 3) Kilka razy w miesiącu 4) Rzadziej 5) Wcale

C4. Kto w firmie inicjuje/rozwija rozwiązania AI w finansach?

1. Finanse/controlling 2) IT/Data 3) Zewnętrzny dostawca 4) Wspólnie 5) Nie dotyczy

#### **Sekcja D. Postrzegane korzyści**

D1. Oceń, na ile zgadzasz się ze stwierdzeniami (1–5):

1 – zdecydowanie nie, 5 – zdecydowanie tak

D1a. AI skraca czas przygotowania raportów.

D1b. AI poprawia trafność prognoz finansowych.

D1c. AI pomaga szybciej wykrywać odchylenia/anomalie.

D1d. AI poprawia jakość decyzji menedżerskich (lepsze wnioski).

D1e. AI zmniejsza liczbę błędów wynikających z pracy ręcznej.

D1f. AI pozwala skupić się na pracy analitycznej, a mniej na „klepaniu” raportów.

*(To jest świetne do zbudowania wskaźnika: średnia z D1a–D1f.)*



## **Sekcja E. Ryzyka i obawy**

E1. Oceń, na ile zgadzasz się (1–5):

E1a. Obawiam się błędów AI wynikających ze złej jakości danych.

E1b. Trudno wyjaśnić wynik modelu (efekt „czarnej skrzynki”).

E1c. AI może powodować nadmierne zaufanie do wyników (automatyzacja bez kontroli).

E1d. AI zwiększa ryzyko naruszeń bezpieczeństwa/RODO.

E1e. AI może ograniczać kontrolę człowieka nad procesem.

E1f. Istnieje ryzyko niewłaściwego użycia AI przez pracowników.

## **Sekcja F. Bariery wdrożeniowe (priorytety)**

F1. Jakie są największe bariery wdrożenia AI w controllingu? (max 3 odpowiedzi)

- Brak kompetencji (AI/data)
- Brak czasu zasobów / priorytetów
- Koszty wdrożenia
- Słaba jakość danych / brak ładu danych
- Brak integracji systemów
- Obawy prawne/RODO/compliance
- Brak wsparcia zarządu
- Brak jasnych przypadków użycia (use case)
- Inne: \_\_\_\_

F2. Ocena gotowości zespołu controllingu do pracy z AI (1–5)

## **Sekcja G. Zaufanie i przyszłość**

G1. Jak oceniasz swój poziom wiedzy o AI w kontekście controllingu?

1. bardzo niski ... 5) bardzo wysoki

G2. Jak oceniasz swoje zaufanie do wyników generowanych przez AI?

1. bardzo niskie ... 5) bardzo wysokie



G3. Które zdanie najlepiej opisuje Twoje podejście?

1. AI to głównie szansa
2. AI to bardziej ryzyko niż szansa
3. Zależy od zastosowania i jakości danych
4. Trudno powiedzieć

G4. W jakim horyzoncie AI istotnie zmieni pracę controllera w Polsce?

1. już zmienia 2) 1-2 lata 3) 3–5 lat 4) >5 lat 5) nie zmieni istotnie



## **Załącznik 2. Scenariusz wywiadu półustrukturyzowanego**

### **Dotyczący wykorzystania sztucznej inteligencji w controllingu finansowym**

#### **Wprowadzenie dla respondenta**

Dziękuję za zgodę na udział w badaniu. Wywiad jest realizowany w ramach pracy magisterskiej pt. „Wykorzystanie sztucznej inteligencji w controllingu finansowym – szanse, zagrożenia i kierunki rozwoju”. Celem rozmowy jest poznanie praktycznych doświadczeń związanych z wykorzystaniem AI w finansach i controllingu. Wywiad ma charakter anonimowy, a uzyskane informacje zostaną wykorzystane wyłącznie do celów naukowych. Rozmowa ma charakter półustrukturyzowany – oznacza to, że pytania stanowią punkt wyjścia do swobodnej wypowiedzi i mogą być rozwijane w zależności od przebiegu rozmowy.

#### **Pytania właściwe**

1. Jakie stanowisko zajmuje Pan/Pani w organizacji i jaki jest zakres obowiązków w obszarze finansów lub controllingu?
2. Jak długo pracuje Pan/Pani w obszarze finansów i czy miał(a) Pan/Pani wcześniej doświadczenie z projektami związanymi z automatyzacją lub analizą danych?
3. Jak ocenia Pan/Pani poziom cyfryzacji oraz integracji systemów finansowych w organizacji?
4. Jak ocenia Pan/Pani jakość danych finansowych wykorzystywanych w controllingu?
5. Czy uważa Pan/Pani, że poziom dojrzałości danych miał istotne znaczenie dla możliwości wdrożenia rozwiązań AI?
6. Czy w Państwa organizacji wykorzystywane są rozwiązania oparte na sztucznej inteligencji w finansach lub controllingu? Jeśli tak, proszę opisać zakres ich zastosowania.
7. Czy rozwiązania te funkcjonują w sposób stały (produkcyjny), czy raczej mają charakter testowy lub pilotażowy?
8. Jakie były główne przesłanki decyzji o wdrożeniu (lub rezygnacji z wdrożenia) AI w controllingu?



9. W jakich konkretnych procesach controllingu AI znajduje największe zastosowanie (np. prognozowanie, budżetowanie, analiza odchyleń, raportowanie)?
10. Czy wdrożenie AI wpłynęło na skrócenie czasu przygotowywania raportów i analiz finansowych?
11. Czy zauważył(a) Pan/Pani poprawę trafności prognoz finansowych dzięki wykorzystaniu AI?
12. Czy wykorzystanie AI wpłynęło na jakość podejmowanych decyzji menedżerskich? Jeśli tak, w jaki sposób?
13. Czy wdrożenie AI zmieniło strukturę pracy zespołu controllingu (np. więcej analiz, mniej pracy manualnej)?
14. Jakie największe korzyści przyniosło zastosowanie AI w controllingu finansowym?
15. Jakie największe ryzyka lub zagrożenia wiążą się – Pana/Pani zdaniem – z wykorzystaniem AI w finansach?
16. Czy w praktyce pojawia się problem trudności w wyjaśnieniu wyników generowanych przez modele AI (tzw. efekt „czarnej skrzynki”)?
17. Czy istnieje ryzyko nadmiernego zaufania do wyników generowanych przez systemy AI bez odpowiedniej kontroli człowieka?
18. Jak organizacja zabezpiecza się przed błędami wynikającymi ze słabej jakości danych lub nieprawidłowego działania modeli?
19. Jakie bariery były najistotniejsze w procesie wdrażania AI (np. brak kompetencji, koszty, integracja systemów, obawy prawne, brak wsparcia zarządu)?
20. Jak ocenia Pan/Pani poziom przygotowania zespołu controllingu do pracy z narzędziami AI?
21. Jakich kompetencji – Pana/Pani zdaniem – najbardziej brakuje w kontekście pracy z AI w finansach?

22. Jak ocenia Pan/Pani poziom zaufania do wyników generowanych przez AI w swojej organizacji?
23. Czy uważa Pan/Pani, że AI w controllingu finansowym jest przede wszystkim szansą czy zagrożeniem dla organizacji? Proszę uzasadnić odpowiedź.
24. W jakim horyzoncie czasowym – Pana/Pani zdaniem – sztuczna inteligencja istotnie zmieni pracę controllera w Polsce?
25. Czy uważa Pan/Pani, że AI może w przyszłości częściowo zastąpić controllerów, czy raczej zmieni charakter ich pracy?
26. Jaką jedną rekomendację dał(a)by Pan/Pani organizacjom planującym wdrożenie AI w controllingu finansowym?

### **Zakończenie**

Dziękuję za poświęcony czas i podzielenie się doświadczeniem. Uzyskane informacje stanowią cenne uzupełnienie badania ankietowego i pozwolą na pogłębioną analizę tematu pracy.



### **Załącznik 3. Wywiad z ekspertem - zapis rozmowy**

#### **1. Jakie stanowisko zajmuje Pan/Pani w organizacji i czym się Pan/Pani zajmuje?**

Jestem Senior Financial Controllerem w dużej organizacji działającej w modelu międzynarodowym. W praktyce odpowiadam za controlling kosztów operacyjnych, analizę odchyleń od budżetu i forecastu oraz przygotowanie raportów dla zarządu. Duża część mojej pracy to nie tylko same liczby, ale też rozmowy z menedżerami operacyjnymi – wyjaśnianie, skąd biorą się różnice, czy są jednorazowe, czy systemowe, i jakie działania można podjąć. W ostatnich latach doszły też tematy związane z usprawnianiem raportowania i automatyzacją.

#### **2. Jak długo pracuje Pan/Pani w finansach i czy miał(a) Pan/Pani doświadczenie z automatyzacją?**

W finansach pracuję około ośmiu lat. Zaczynałem od klasycznego raportowania w Excelu – dużo ręcznej pracy, łączenie plików, przygotowywanie prezentacji. Z czasem zaczęliśmy wprowadzać Power Query i Power BI, żeby to usprawnić. Automatyzacja była naturalnym krokiem, bo liczba danych rosła, a oczekiwania zarządu były coraz większe. Z AI pierwszy kontakt miałem kilka lat temu, kiedy zaczęliśmy testować modele wspierające prognozy.

#### **3. Jak ocenia Pan/Pani poziom cyfryzacji i integracji systemów finansowych?**

Powiedział(a)bym, że jesteśmy na dość dobrym poziomie. Mamy centralny system ERP, hurtownię danych i raportujemy w BI. Dane finansowe są zintegrowane, co ułatwia pracę. Natomiast kiedy zaczęliśmy wdrażać bardziej zaawansowane rozwiązania, okazało się, że integracja danych operacyjnych – np. wolumenów, wskaźników produkcyjnych czy sprzedażowych – z finansami nie zawsze jest idealna. I to właśnie tam pojawiały się pierwsze wyzwania przy projektach AI.

#### **4. Jak ocenia Pan/Pani jakość danych finansowych wykorzystywanych w controllingu?**

Jeśli chodzi o dane księgowe, są raczej dobrej jakości – procesy są ustandaryzowane i regularnie kontrolowane. Natomiast controlling korzysta też z danych pomocniczych, które nie zawsze są tak spójne. Czasami różne jednostki stosują inne nazewnictwo czy klasyfikację kosztów. To nie są duże błędy, ale przy modelach predykcyjnych nawet drobne niespójności potrafią mieć znaczenie.



## **5. Czy poziom dojrzałości danych miał znaczenie przy wdrażaniu AI?**

Zdecydowanie tak. Na początku mieliśmy podejście „technologiczne” – czyli skoro mamy narzędzie, to możemy je wdrożyć. Szybko jednak okazało się, że bez uporządkowanych danych efekty są słabsze, niż oczekiwaliśmy. W praktyce najpierw trzeba było dopracować definicje wskaźników, strukturę danych i sposób ich integracji. Dopiero wtedy AI zaczęła przynosić realną wartość.

## **6. Czy w organizacji wykorzystywane są rozwiązania oparte na AI?**

Tak, korzystamy z kilku rozwiązań. W prognozowaniu wybranych kategorii kosztów mamy model, który analizuje dane historyczne i wskazuje trend. W analizie odchyleń system potrafi zidentyfikować nietypowe wartości, które wymagają sprawdzenia. Używamy też narzędzi generatywnych do przygotowania wstępnych wersji komentarzy do raportów, co przyspiesza pracę.

## **7. Czy to działa produkcyjnie czy raczej testowo?**

Część działa już w sposób stały – szczególnie analiza anomalii i wsparcie raportowania. Modele prognozujące są wykorzystywane regularnie, ale wciąż je dostrajamy. Nie traktujemy ich jako „ostatecznej prawdy”, raczej jako dodatkowe źródło informacji.

## **8. Co było główną motywacją do wdrożenia AI?**

Przede wszystkim efektywność. Raportowanie stawało się coraz bardziej czasochłonne, a zarząd oczekiwał szybszych i bardziej pogłębionych analiz. Chcieliśmy ograniczyć ręczną pracę i skupić się na interpretacji danych, a nie tylko ich przetwarzaniu.

## **9. W jakich procesach AI sprawdza się najlepiej?**

Największy efekt widzimy w prognozowaniu i analizie odchyleń. Tam mamy dużo danych historycznych i powtarzalnych zależności, więc model może się „nauczyć” pewnych schematów. W raportowaniu AI pomaga przygotować pierwszy szkic komentarza, który później dopracowujemy.

## **10. Czy skrócił się czas przygotowania raportów?**

Tak, szczególnie w części przygotowawczej. Nadal potrzebna jest analiza i weryfikacja, ale szybciej wychytujemy obszary wymagające uwagi i nie musimy ręcznie przeglądać wszystkich danych.



### **11. Czy poprawiła się trafność prognoz?**

W stabilnych obszarach – tak. Model potrafi lepiej wychwycić trend niż prosta metoda liniowa. Natomiast w sytuacjach niestandardowych – jak reorganizacje czy nagłe zmiany cen – nadal kluczowa jest wiedza ekspercka

### **12. Czy AI wpłynęła na jakość decyzji menedżerskich?**

Wpłynęła pośrednio. Dzięki szybszym i bardziej uporządkowanym analizom menedżerowie wcześniej widzą sygnały ostrzegawcze. Decyzje nadal podejmują ludzie, ale mają lepsze wsparcie informacyjne.

### **13. Czy zmieniła się praca zespołu controllingu?**

Tak, zdecydowanie. Mniej czasu poświęcamy na czynności manualne, więcej na analizę i rozmowy z biznesem. Pojawiła się też odpowiedzialność za kontrolę jakości danych i wyników generowanych przez systemy.

### **14. Jakie największe korzyści przyniosło zastosowanie AI?**

Największą korzyścią jest oszczędność czasu i szybsze wykrywanie nieprawidłowości. Dodatkowo proces raportowania stał się bardziej uporządkowany.

### **15. Jakie największe ryzyka Pan/Pani dostrzega w wykorzystaniu AI w finansach?**

Największym ryzykiem jest jakość danych. Jeżeli dane wejściowe są niepełne, niespójne albo źle sklasyfikowane, to nawet najlepszy model będzie dawał błędne wnioski. Druga rzecz to tzw. „czarna skrzynka”. W praktyce chodzi o sytuację, w której model generuje wynik, ale trudno jednoznacznie wyjaśnić, na jakiej podstawie podjął taką decyzję. Dla controllingu to jest problem, bo my musimy umieć uzasadnić liczby przed zarządem. Jeżeli nie rozumiemy logiki modelu, to trudno w pełni zaufać jego rekomendacjom. No i trzecie ryzyko – nadmierne uproszczenie. Czasem można ulec wrażeniu, że skoro system coś wskazał, to temat jest zamknięty, a to jednak tak nie działa.

### **16. Czy występuje problem „czarnej skrzynki”?**

Tak, czasami. Szczególnie przy bardziej złożonych modelach. W prostych narzędziach jesteśmy w stanie zobaczyć, które zmienne mają największy wpływ na wynik, ale przy bardziej zaawansowanych rozwiązaniach nie zawsze jest to oczywiste. Dlatego staramy się korzystać z modeli, które da się przynajmniej częściowo zinterpretować. W controllingu bardzo ważne jest, żeby wiedzieć nie tylko „co”, ale też „dlaczego”.



## **17. Czy istnieje ryzyko nadmiernego zaufania do wyników AI?**

Tak, i to realne. Szczególnie gdy zespół jest pod presją czasu i ma dużo obowiązków. Łatwo jest przyjąć wynik modelu jako gotową odpowiedź. Dlatego u nas obowiązuje zasada, że AI jest wsparciem, a nie zastępstwem dla analizy. Każdy wynik musi zostać przejrany i oceniony przez controllera. W praktyce traktujemy AI jako dodatkowego „asystenta”, a nie jako osobę decyzyjną.

## **18. Jak organizacja zabezpiecza się przed błędami wynikającymi ze słabej jakości danych lub działania modeli?**

Przede wszystkim mamy dodatkowe kontrole jakości danych. Są reguły walidacyjne, sprawdzanie odchyleń względem poprzednich okresów, porównania z klasycznymi metodami prognozowania. Modele są też regularnie przeglądane i aktualizowane. Jeżeli widzimy, że zaczynają odbiegać od rzeczywistości, to analizujemy przyczynę. Nie zostawiamy systemu „samemu sobie”. Jest też jasno określona odpowiedzialność – ktoś zawsze odpowiada za wynik i jego interpretację.

## **19. Co było najtrudniejsze przy wdrożeniu AI?**

Najtrudniejsze było przygotowanie ludzi i uporządkowanie danych. Technologia sama w sobie nie była największym wyzwaniem, bo dostawcy oferują gotowe rozwiązania. Trudniejsze było zbudowanie zrozumienia w zespole – wyjaśnienie, czym jest AI, czego można się spodziewać, a czego nie. Była też naturalna obawa, czy to nie oznacza redukcji etatów albo zmiany roli. W praktyce bardziej zmienił się sposób pracy niż liczba osób.

## **20. Jak ocenia Pan/Pani przygotowanie zespołu controllingu do pracy z narzędziami AI?**

Ocenił(a)bym je jako umiarkowane, z tendencją wzrostową. Są osoby, które bardzo szybko adaptują nowe narzędzia i same szukają usprawnień. Są też osoby, które potrzebują więcej czasu i wsparcia. To naturalne, bo AI w finansach to wciąż stosunkowo nowy temat. Widzimy jednak, że z każdym projektem rośnie komfort pracy z takimi rozwiązaniami.

## **21. Jakich kompetencji – Pana/Pani zdaniem – najbardziej brakuje w kontekście pracy z AI w finansach?**

Przede wszystkim kompetencji związanych z pracą na danych – rozumienia, jak dane są zbudowane, jakie mają ograniczenia, jak interpretować wyniki modeli. Nie chodzi o to, żeby każdy był programistą, ale żeby rozumiał logikę działania narzędzi. Przydaje się też krytyczne

myślenie i umiejętność zadawania właściwych pytań systemowi. No i kompetencje komunikacyjne – bo trzeba umieć wytłumaczyć wyniki AI osobom nietechnicznym.

## **22. Jak ocenia Pan/Pani poziom zaufania do wyników generowanych przez AI w swojej organizacji?**

Powiedział(a)bym, że jest umiarkowanie wysoki, ale warunkowy. Zaufanie rośnie wraz z doświadczeniem i z tym, jak dobrze model się sprawdza w praktyce. Im więcej sytuacji, w których AI faktycznie pomogła wykryć problem albo poprawnie wskazała trend, tym większa akceptacja w zespole. Natomiast nadal jest świadomość, że to narzędzie wspierające.

## **23. Czy uważa Pan/Pani, że AI w controllingu finansowym jest przede wszystkim szansą czy zagrożeniem?**

Z mojego punktu widzenia to przede wszystkim szansa. Pozwala nam pracować efektywniej i skupić się na analizie zamiast na ręcznej pracy. Oczywiście są ryzyka, ale one wynikają głównie z niewłaściwego wdrożenia albo braku kontroli. Jeżeli organizacja podchodzi do tematu odpowiedzialnie, to bilans jest zdecydowanie pozytywny.

## **24. W jakim horyzoncie czasowym sztuczna inteligencja istotnie zmieni pracę controllera w Polsce?**

Moim zdaniem już zmienia, ale największe zmiany zobaczymy w perspektywie 3–5 lat. Coraz więcej raportowania będzie automatyzowane, a controlling będzie przesuwiał się w stronę analizy predykcyjnej i wsparcia strategicznego. Rola będzie bardziej doradcza niż operacyjna.

## **25. Czy AI może w przyszłości częściowo zastąpić controllerów, czy raczej zmieni charakter ich pracy?**

Nie sądzę, żeby zastąpiła controllerów. Raczej przejmie część rutynowych zadań. Charakter pracy się zmieni – będzie mniej ręcznego raportowania, więcej interpretacji danych, współpracy z biznesem i kontroli jakości informacji. W pewnym sensie rola controllera może nawet stać się bardziej strategiczna.

## **26. Jaka jedną rekomendację dał(a)by Pan/Pani organizacjom planującym wdrożenie AI w controllingu finansowym?**

Zacząć od fundamentów – czyli od danych i jasno określonego celu. Lepiej wybrać jeden konkretny proces, w którym AI może przynieść widoczną wartość, niż próbować wdrażać wszystko jednocześnie. I od początku ustalić zasady: kto odpowiada za wyniki, jak są weryfikowane i jak chronione są dane.

