

## Sztuczna inteligencja w innowacjach finansowych – aspekty prawne i regulacyjne

### Spis treści

- I. Wprowadzenie
- II. Sztuczna inteligencja i uczenie maszynowe
- III. Analizy dużych zbiorów danych (*Big Data*)
- IV. Nowoczesna analityka danych na przykładzie *scoringu* kredytowego
- V. Wykrywanie nadużyć i transakcji podejrzanych
- VI. *Robo-advisory* w doradztwie inwestycyjnym
- VII. Podsumowanie

### Streszczenie

Celem artykułu jest przeanalizowanie prawnych konsekwencji wdrażania nowoczesnych technik przetwarzania danych, w szczególności uczenia maszynowego oraz analizy dużych zbiorów danych (*Big Data*) w sektorze innowacji finansowych (*fintech*). Techniki te stanowią nie tylko tworzą nowe możliwości monetaryzacji danych po stronie podmiotów funkcjonujących w sektorze finansowym, lecz także ujawniają nowe wyzwania regulacyjne i nadzorcze.

**Słowa kluczowe:** sztuczna inteligencja; uczenie maszynowe; *Big Data*; *fintech*; *scoring* kredytowy.

**JEL:** K24

### I. Wprowadzenie

Cechą charakterystyczną próby regulacji każdego nowego rynku są początkowe trudności z jego precyzyjnym zdefiniowaniem. Nie inaczej jest z sektorem *fintech* – który pomimo dynamicznego rozwoju i rosnącego udziału w segmencie usług finansowych, nadal przysparza trudności definicyjnych. Połączenie usług finansowych z nowoczesną technologią tworzy nowe możliwości, ale również liczne problemy interpretacyjne. Biorąc pod uwagę stopień sformalizowania świadczenia różnych typów usług finansowych (bankowych, płatniczych, kredytowych itp.), ewolucja tak ukształtowanego rynku z wykorzystaniem nowoczesnych technologii musi prowadzić do rewizji istniejących przepisów prawnych, a w niektórych przypadkach nawet rozważenia zasadności ich dalszego funkcjonowania.

Dokonując przeglądu nowoczesnych form przetwarzania informacji, które już dzisiaj znajdują praktyczne zastosowanie w działalności podmiotów *fintech*, bez wątpienia do najbardziej

\* Adiunkt na Wydziale Administracji i Nauk Społecznych Politechniki Warszawskiej; e-mail: m.rojszczak@ans.pw.edu.pl; <https://orcid.org/0000-0003-2037-4301>.

zaawansowanych należy zaliczyć systemy sztucznej inteligencji (SI). Tego typu systemy znajdują się w awangardzie przemian technologicznych, ale również – z uwagi na swoją specyfikę – posiadają potencjał do znacznego przekształcenia znanego współcześnie rynku usług finansowych.

Omówienie możliwości i zagrożeń związanych z systemami SI wymaga także odniesienia do analityki dużych zbiorów danych (*Big Data*). Dynamiczny rozwój rynku *Big Data* w istocie umożliwił bowiem pojawienie się wielu innowacji finansowych. Bez *Big Data* nie byłoby możliwe zaawansowane profilowanie użytkowników, stanowiące fundament większości usług e-commerce. Zastosowania, takie jak wykrywanie nadużyć czy zwalczanie finansowania terroryzmu byłyby mniej skuteczne, gdyby nie wykorzystanie dostępu do wielu rozproszonych baz danych. Rozwój *Big Data* był także katalizatorem dla opracowania nowych algorytmów uczenia maszynowego, które z kolei są postrzegane jako etap pośredni poprzedzający powstanie systemów sztucznej inteligencji. Symbioza pomiędzy *Big Data* oraz SI jest więc wyraźna i nierozzerwalna, a połączenie obu tych technologii prowadzi do uwolnienia potencjału związanego z nowoczesną analityką danych.

Dlatego w pierwszej kolejności omówiona zostanie dotychczasowa ewolucja, najważniejsze definicje oraz ograniczenia algorytmów sztucznej inteligencji oraz analityki *Big Data*. Dopiero po wprowadzeniu i wyjaśnieniu najważniejszych pojęć, przedstawione zostaną szczegółowe rozważania dotyczące konkretnych zastosowań SI w branży finansowej – związane z oceną wiarygodności kredytowej klientów, wykrywaniem nadużyć oraz automatycznym doradztwem inwestycyjnym.

## II. Sztuczna inteligencja i uczenie maszynowe

Chociaż od wprowadzenia terminu „sztuczna inteligencja” do dyskursu naukowego minęło ponad sześćdziesiąt lat, nadal nie wypracowano jednej, powszechnie akceptowanej definicji tego pojęcia. Co więcej, z uwagi na mnogość publikacji oraz zainteresowanie tą materią badań ze strony przedstawicieli różnych dziedzin wiedzy, odnaleźć można różne – czasami sprzeczne – definicje (Różanowski, 2017, s. 110–111). Z pewnością, uwzględniając dzisiejszy stan badań nad SI, użycie zarówno przymiotnika „sztuczna”, jak i rzeczownika „inteligencja” nie należy uznać za szczególnie udane. Inteligencja *sztuczna* tym bowiem miała się odróżniać od *naturalnej*, że powstałaby w wyniku aktywności człowieka. W czasach dynamicznego rozwoju bioinżynierii, w tym manipulacji ludzkim DNA, wprowadzanie do języka nauki pojęć mogących skutkować nieuprawnioną dyskryminacją nie wydaje się być jednak właściwe. Także odnoszenie terminu „inteligencja” do algorytmów informatycznych może prowadzić do prostych porównań ze sposobem funkcjonowania ludzkiego mózgu. Na tym tle natychmiast pojawiają się jednak wątpliwości związane z utożsamianiem mózgu i umysłu, a w dalszej kolejności umysłu z duszą człowieka. Przypisywanie maszynom cech ludzkich nieuchronnie prowadzi do sporów pozanaukowych, a przez to utrudnia skupienie się na faktycznej istocie zagadnienia.

W połowie dwudziestego wieku sztuczna inteligencja postrzegana była jako system działający na wzór ludzkiego umysłu. W efekcie miała być zdolna do rozwiązywania problemów w sposób podobny do ludzi, z tą różnicą, że mogłaby to robić szybciej, a przez to bardziej efektywnie. System działający w ten sposób posiadałby zdolność do podejmowania własnych decyzji, a z uwagi na sposób jego działania – także, w pewnym zakresie, mógłby zostać uznany za samoświadomy. Zwolennikiem takiego pojmowania SI był A. Turing, który zdefiniował także pierwszy test służący potwierdzeniu czy badany system osiągnął stopień rozwoju pozwalający na uznanie go za system

sztucznej inteligencji<sup>1</sup>. Algorytmy zdolne do rozwiązywania dowolnych problemów, które rozwiązać potrafi człowiek określane są w nauce terminem „silnej SI”.

Wraz z postępem techniki szybko okazało się jednak, że próba algorytmicznego odwzorowania sposobu działania ludzkiego umysłu jest zadaniem dużo bardziej skomplikowanym, niż początkowo sądzono. Dodatkowo rozwój inżynierii (w szczególności automatyki i informatyki) skutkowało pojawieniem się nowej kategorii wysokospecjalistycznych systemów informatycznych, pozwalających na wykonywanie skomplikowanych zadań i to ze skutkiem lepszym, niż gdy były one realizowane przez ludzi. Opracowano także pierwsze systemy wygrywające z ludźmi w gry logiczne, co powszechnie postrzegano jako dowód zdolności algorytmów do twórczego rozwiązywania skomplikowanych problemów. Tego typu systemy, chociaż potrafią samodzielnie rozwiązywać konkretne typy zadań, nie posiadają umiejętności analizowania dowolnych kategorii problemów – w żadnym stopniu nie stanowią zatem realizacji koncepcji cyfrowego umysłu. W literaturze określa się je terminem „słabej SI”

Podział na silną i słabą SI unaocznia nie tylko odmienne wyobrażenia oraz oczekiwania związane ze sztuczną inteligencją, lecz także obrazuje problemy interpretacyjne narosłe wokół tej koncepcji na przestrzeni ostatnich pięćdziesięciu lat. Według dzisiejszego stanu wiedzy, nie istnieje żaden system, który mógłby zostać zakwalifikowany jako silna SI<sup>2</sup>. Obecnie oczekuje się, że systemy takie powstaną w ciągu najbliższych kilkudziesięciu lat<sup>3</sup>. Wiodące badania w zakresie silnej SI od lat prowadzone są w ośrodkach naukowych w Stanach Zjednoczonych i Chinach.

Większość z obecnie działających lub projektowanych systemów określanymi pojęciem „sztucznej inteligencji” w ogóle nie powinna być zaliczana do tej kategorii, a co najwyżej powinna być klasyfikowana jako prekursorzy systemów słabej SI. Systemy te potrafią sprawnie rozwiązywać określoną kategorię problemów, jednak służą realizacji konkretnych celów i tylko w tym zakresie można mówić o ich (częściowej) samodzielności.

Pomijając chwilowo implikacje prawne i etyczne związane z uznaniem algorytmu informatycznego jako spełniającego kryteria uznania go za sztuczną inteligencję, krótkiego wyjaśnienia wymaga jego zdolność do podejmowania własnych decyzji. Z perspektywy obecnych zastosowań informatyki jest bowiem oczywiste, że szereg istniejących systemów informatycznych może podejmować określone typy decyzji, nie są to jednak decyzje samodzielne. Systemy te wykonują przewidziany przez programistów algorytm (kod programu), stosując określone kryteria i warunki w celu ustalenia dalszych kroków programu. Decyzje te są jednak skutkiem podążania za wyznaczonym algorytmem, nie mogą zatem być uznane za będące przejawem samodzielnych decyzji. Inaczej sytuacja ma się w odniesieniu do systemów SI – w ich bowiem przypadku decyzje podejmowane przez algorytm będą konsekwencją wiedzy i wniosków, które program zbudował w sposób samodzielny (np. w wyniku analizy dużych zbiorów danych). Jest jednak oczywiste,

<sup>1</sup> Tzw. test Turinga polegał na prowadzeniu przez wyznaczonego uczestnika (tzw. sędziego) komunikacji za pośrednictwem komputera, a następnie ocenie czy rozmówca jest człowiekiem, czy systemem informatycznym. W założeniach autora rozmowa miała być prowadzona na dowolny temat. Pomimo swojej innowacyjności test Turinga jest także krytykowany jako de facto obliczony na potwierdzenie, że maszyna potrafi udawać człowieka (zob. także: Piesko, 2002, s. 93–102); oryginalny artykuł A. Turinga dostępny online (Turing, 1950, s. 433–460).

<sup>2</sup> Oceny tej nie zmienia fakt pojawienia się pierwszego przypadku nadania obywatelstwa androidowi Sofia przez władze Arabii Saudyjskiej. Chociaż jego twórcy dowodzą, że jest to robot sterowany systemem sztucznej inteligencji, to deklaracja ta wydaje się nie znajdować potwierdzenia w faktach. Niemniej jednak funkcjonowanie w przestrzeni prawnej systemu autonomicznego posiadającego obywatelstwo uznanego międzynarodowo państwa tworzy ciekawy kasus prawny (więcej: Rojszczak, 2019c).


<sup>3</sup> Wniosek ten bazuje na szeregu założeń odnośnie do rozwoju poszczególnych dziedzin nauki. W szczególności ocenia się, że złożoność i wydajność procesorów będzie ok. roku 2025–2030 obliczeniowo równoważna ludzkiemu mózgowi. To jednak per se nie przesądza o możliwości zbudowania systemu, który będzie spełniał kryteria silnej SI. Ciekawe rozwinięcie tematu w: McGinnis, 2009–2010, s. 368–372.

że niezależnie od zaawansowania algorytmów SI i ich zdolności do budowania własnej wiedzy, sposób ich działania zawsze może być warunkowany przez początkowy kod programu. Dlatego w przypadku SI „samodzielność podejmowanych decyzji” służy raczej do opisu możliwości technicznych wykorzystanych algorytmów (posiadających możliwość do zbudowania wniosków wykraczających poza początkowe programowanie) niż faktyczną ich niezależność, rozumianą w sensie prawnym. Aspekt ten ma kluczowe znaczenie praktyczne, np. w zakresie określania podmiotów odpowiedzialnych za decyzje podejmowane przez SI.

Pojęciem często zamiennie stosowanym ze sztuczną inteligencją jest „uczenie maszynowe” (*machine learning*). To uproszczenie, prowadzące do błędów. Systemy uczenia maszynowego posiadają zdolność do budowania nowej wiedzy na podstawie własnych algorytmów wnioskujących, zazwyczaj bazujących na dużych zbiorach dostępnych informacji. Proces ten – zwany odkrywaniem wiedzy – polega na odnajdywaniu nieoczywistych powiązań, które ujawniają nowe zależności (fakty). W ostatnich latach algorytmy uczenia maszynowego znajdują zastosowanie w wielu sektorach gospodarki – między innymi wszędzie tam, gdzie pomocne jest przewidywanie zachowań dużych grup ludzi lub pojedynczych jednostek. W ten sposób systemy te pomagają wpływać na preferencje wyborcze, przewidywać decyzje zakupowe oraz ujawniać cechy jednostki (w tym dane wrażliwe – np. informacje o stanie zdrowia, nałogach, życiu osobistym) na podstawie wzorców zachowań. Uczenie maszynowe znajduje także szerokie zastosowanie w sektorze finansowym – począwszy od wykrywania nadużyć finansowych i realizacji procedur kontrolnych, poprzez badanie wskaźników ryzyka na doradztwie inwestycyjnym skończywszy. Jednak to, co odróżnia uczenie maszynowe od sztucznej inteligencji to zakres swobody w podejmowaniu decyzji. Uczenie maszynowe służy pozyskaniu (odkryciu) wiedzy, natomiast celem działania SI jest rozwiązywanie konkretnej kategorii problemów. Rozgraniczenie to w praktyce nie zawsze jest jednak proste. Przykładowo, handel algorytmiczny jest obszarem wykorzystania systemów uczenia maszynowego, tak jak proste usługi doradztwa inwestycyjnego (prognozowanie zmian cen instrumentów finansowych). Oba te zastosowania można jednak opisać w taki sposób, że będą również spełniały definicję systemów słabej SI.

Dlatego biorąc pod uwagę współczesne zaawansowanie techniki, algorytmy wykorzystywane na rynku *fintech* powinny być zaliczane do kategorii systemów uczenia maszynowego – a używanie w odniesieniu do nich terminu sztucznej inteligencji ma raczej na celu podkreślenie ich innowacyjnego charakteru niż faktycznych możliwości technicznych. Stąd też w dalszej części rozważań przez pojęcie SI będą w istocie rozumiane systemy uczenia maszynowego.

**Rysunek 1.** Zależności pomiędzy SI, *Big Data* a uczeniem maszynowym



### III. Analizy dużych zbiorów danych (*Big Data*)

Zagadnieniem nierozzerwalnie związanym z systemami uczenia maszynowego jest analityka dużych zbiorów danych (*Big Data*). Podobnie jak w przypadku sztucznej inteligencji, w odniesieniu do *Big Data* istnieje wiele definicji, za pomocą których ich autorzy próbują opisać tę technikę przetwarzania danych. Część ekspertów wskazuje na powiązanie *Big Data* z popularną od lat osiemdziesiątych techniką *data miningu*. Celem *data miningu* było odnajdywanie nowych powiązań pomiędzy danymi, a przez to odkrywanie nieznanych wcześniej zależności. Analityka *Big Data* realizuje to samo zadanie, ale korzystając do tego z wielu wzajemnie skorelowanych baz danych, pochodzących z różnych źródeł. Często są to dane publicznie dostępne, np. pochodzące z Internetu lub poddane wcześniejszej anonimizacji.

*Big Data* to jednak nie tylko sposób analizy danych, ale cały proces związany z ich przetwarzaniem. Można w nim wyodrębnić cztery główne etapy:

- (1) gromadzenie danych;
- (2) ich agregacja i korelacja;
- (3) analiza oraz
- (4) wykorzystanie wniosków (Rojszczak, 2019b, s. 384).

Potencjał związany z analizą dużych zbiorów danych był w ostatnich latach przez wielu przeceniany<sup>4</sup>. Często prezentowano *Big Data* jako technikę pozwalającą na uzyskanie odpowiedzi na każde pytanie, jeżeli tylko zapewni się dostęp do odpowiednio dużego zbioru danych. W ten sposób w *Big Data* postrzegano metody analizy idealnej w zastosowaniach tak różnych, jak badania społeczne, ochrona zdrowia czy doskonalenie procesów przemysłowych i produkcyjnych.

Analizy *Big Data* mają kilka cech charakterystycznych, których wyjaśnienie pozwoli zrozumieć potencjał, ale i ograniczenia związane z tą techniką analizy danych. Do najważniejszych należą:

- (1) różna jakość danych źródłowych;
- (2) heurystyczne algorytmy wnioskowania;
- (3) stały przyrost danych oraz
- (4) zmienne w czasie wnioski.

Pierwsza z cech – związana z różną jakością danych – jest często niedoceniana w praktyce. Łączenie dużych zbiorów danych, pochodzących z różnych źródeł i często uzyskanych w odmienny sposób, uwidacznia błędy i przekładania. Problem ten narasta, jeżeli dane pochodzą z ogólnodostępnych źródeł, np. z portali internetowych. Proces zapewniania spójności danych – tzw. oczyszczanie danych – w przypadku *Big Data* nie zawsze prowadzi do zwiększenia ich jakości, ponieważ z uwagi na ogrom informacji również jest realizowany automatycznie (Maletic i Marcus, 2019, s. 19–32).

Praktycy wskazują, że konsekwencje błędów w danych źródłowych mogą być zniwelowane dzięki zastosowaniu zaawansowanych algorytmów (SI). W tym zakresie należy jednak pamiętać, że wynik działania wielu z tego typu algorytmów jest trudny – a często nawet niemożliwy – do przewidzenia, stąd też często bywa porównywany do algorytmów heurystycznych. Dlatego

<sup>4</sup> Jeszcze w 2008 roku w piśmiennictwie odnaleźć można było skrajnie optymistyczne opinie wskazujące na *Big Data* jako technikę pozwalającą odpowiedzieć na każdy problem badawczy: [*Big Data*] „to świat, gdzie olbrzymie ilości danych i algorytmy matematyczne zastępują wszelkie inne narzędzia, jakie można brać pod uwagę. Zapomnij o taksonomii, ontologii i psychologii. Kto może wiedzieć dlaczego ludzie robią to co robią? Ważne, że to robią a my możemy to obserwować i zmierzyć z nieznaną wcześniej precyzją. Dysponując odpowiednią ilością danych, liczby mówią same za siebie” (zob.: Anderson, 2008).

w przypadku *Big Data* statystyczna poprawność wyników nie może być wystarczającym dowodem na ich prawdziwość w każdym indywidualnym przypadku.

Kolejna cecha *Big Data*, o fundamentalnym znaczeniu praktycznym, to tzw. efekt przyrostowy. Analizy *Big Data* bazują na zmiennych w czasie danych źródłowych. Oznacza to, że realizując ten sam algorytm – ale w różnym czasie – system może dojść do odmiennych wniosków. W ogólności im dłużej działa algorytm i dłużej uzupełniane są dane źródłowe, tym większa pewność co do poprawności uzyskiwanych danych. Efekt przyrostowy – chociaż stanowi dużą zaletę korzystania z *Big Data* – może mieć także konsekwencje. Jedną z nich jest ryzyko naruszenia praw jednostek, których dane podlegają analizie, w wyniku ujawnienia faktów czy zdarzeń z ich życia prywatnego.

Połączenie powyższych cech prowadzi do konkluzji, że jedną z cech immamentnie związanych z *Big Data* jest zmienność w czasie uzyskiwanych wyników. Każda metoda analityczna obciążona jest pewnym marginesem błędu. W przypadku *Big Data*, z uwag na masową skalę prowadzonych czynności przetwarzania oraz brak danych porównawczych, często jednak istnieje praktyczna trudność w określeniu tego marginesu.

Wszystkie przedstawione cechy *Big Data* mają bezpośrednie odniesienie do zastosowań SI w segmencie usług finansowych. Ograniczenia związane z *Big Data* wpływają bowiem na jakość prowadzonej analizy. Podstawą działania systemów SI jest ciągły proces uczenia (często określanego jako „głębokie uczenie”, *deep learning*) w oparciu o dostarczane informacje. Dane niskiej jakości, obciążone błędami czy przekłamaniem mogą mieć nie tylko wpływ na jakość bieżącej analizy, ale skutkować także długoterminowym obniżeniem jej skuteczności<sup>5</sup>.

#### IV. Nowoczesna analityka danych na przykładzie *scoringu* kredytowego

Dostawcy usług finansowych od wielu lat interesują się możliwościami wynikającymi z praktycznego zastosowania systemów sztucznej inteligencji. Nie bez przyczyny A. Bhalla, wiceprezes Mastercard, omawiając zainteresowanie technologią SI, wyjaśnił, że „jeśli dane są paliwem napędzającym gospodarkę cyfrową, to sztuczna inteligencja jest rafinerią”<sup>6</sup>. Współczesne usługi finansowe opierają się na danych elektronicznych. Dlatego każda technologia, która zapewnia skuteczniejsze gromadzenie lub przetwarzanie informacji postrzegana jest w kategoriach przewagi konkurencyjnej.

Naturalnym obszarem zastosowania SI w sektorze finansowym jest wyliczanie różnego rodzaju wskaźników ryzyka, w szczególności zaś oceny ryzyka (*scoringu*) kredytowego klientów. Zagadnienie to nie powinno być jednak postrzegane wyłącznie przez pryzmat możliwych negatywnych skutków dla jednostki. Wiarygodny *scoring* kredytowy to także obniżanie kosztu usługi finansowej, a co za tym idzie możliwość poprawienia jej parametrów dostępnych dla konsumenta. Aspekt ten, chociaż dostrzegalny w prowadzonych analizach (Financial Services User Group 2016, 2019, s. 3), wydaje się być mniej zauważalny w debacie publicznej i ustępować przekonaniu, że korzyści wynikające z zastosowania SI w miejsce tradycyjnych modeli analitycznych zostaną w całości skonsumowane przez dostawców usług finansowych.

<sup>5</sup> Należy także pamiętać, że manipulowanie danymi źródłowymi jest techniką ataku na prawidłowość działania systemów uczenia maszynowego (zob.: np.: Hutson, 2018).

<sup>6</sup> Kredyt tylko od AI, Money.pl 14.11.2018, <https://cli.re/GXE414> (dostęp: 1.04.2019).

Od lat obliczanie wskaźników kredytowych to obszar praktycznej implementacji zaawansowanych modeli decyzyjnych, opartych na specjalnych arkuszach (kartach) oceny ryzyka oraz informacjach statystycznych. W modelu wykorzystywanych jest maksymalnie kilkadziesiąt (zwykle kilkanaście) z góry zdefiniowanych parametrów, odpowiadających różnym cechom kredytobiorcy (np. wiek, zawód, stan cywilny), jego sytuacji majątkowej (posiadane aktywa oraz zobowiązania) czy wykorzystywanym produktom finansowym oraz dotychczasowej historii kredytowej. Pomimo swojego skomplikowania tego typu modele mają jednak szereg ograniczeń – a podstawowym jest sposób ich funkcjonowania, polegający na stosowaniu uśrednionych wag do oceny różnych kredytobiorców.

Zastosowanie algorytmów SI pozwala na pokonanie tych ograniczeń. System może oceniać każdy wniosek kredytowy, uzupełniając analizę wskaźnikową o dane pochodzące z wielu rozproszonych baz – prowadząc *de facto* do opracowania zaawansowanego profilu kredytobiorcy, który następnie zestawiany jest z profilami innych kredytobiorców i historią spłaty zaciągniętych przez nich zobowiązań. Pewnym wglądem w to, jak może wyglądać profilowanie klientów na potrzeby usług finansowych dostarcza raport przygotowany przez amerykańską Federalną Komisję Handlu, w którym badaniu poddano rynek tzw. brokerów danych (*data broker*) – a więc podmiotów profesjonalnie zajmujących się gromadzeniem rozbudowanych informacji na temat konsumentów (Federal Trade Commission, 2015). FTC wskazała, że dla każdego profilu konsumenta, badani brokerzy gromadzili kilkadziesiąt kategorii danych. Poza podstawowymi informacjami, wykorzystywanymi także w klasycznych modelach scoringowych (wykształcenie, zawód, liczba dzieci itp.) były to także szczegółowe dane demograficzne, informacje pochodzące z rejestrów publicznych (np. ogłoszone postępowania upadłościowe, informacje z rejestrów karnych), mediów społecznościowych (zagregowane informacje na temat aktywności online, dane na temat posiadanych kont w portalach społecznościowych, rodzaju publikowanych treści), informacje na temat miejsca zamieszkania oraz sąsiedztwa (w tym dane związane z przestępczością), posiadanych środków transportu, szczegółowe dane finansowe, informacje o stanie zdrowia, sposobie spędzania wolnego czasu oraz szczegółowe preferencje dotyczące zakupów. Badane firmy gromadziły nawet informacje na temat ulubionych programów telewizyjnych, prenumerowanych czasopismach, udziału w biletowanych wydarzeniach sportowych oraz akcjach charytatywnych czy upodobaniu do hazardu – z wyróżnieniem kasyn oraz loterii stanowych (Rojszczak, 2019b, s. 399–402).

Tak szczegółowe informacje mogą być wykorzystane do opracowania bardziej precyzyjnych wskaźników oceny ryzyka – nie tylko na potrzeby oceny ryzyka kredytowego, ale na przykład – ryzyka ubezpieczeniowego. Kredytodawca może być mniej zainteresowany zapewnieniem finansowania osobie, która przejawia zainteresowanie hazardem. Z kolei firma ubezpieczeniowa może zaproponować mniej atrakcyjne składki w przypadku, gdy ubezpieczony mieszka w okolicy cechującej się wyższymi wskaźnikami przestępczości.

W ostatnich latach coraz częściej prezentowane są badania dotyczące możliwości prowadzenia scoringu kredytowego wyłącznie w oparciu o dane pochodzące z portali społecznościowych (Seleda, 2013). Chociaż obecnie wskazuje się, że dokładność uzyskiwanych w ten sposób wyników jest niewystarczająca<sup>7</sup>, to uwzględniając specyfikę *Big Data* (efekt przyrostowy) oraz stałe doskonalenie algorytmów wnioskujących SI (*deep learning*) należy przyjąć, że wkrótce takie

<sup>7</sup> Zob. np. ograniczenia związane z budowaniem scoringu na danych pochodzących z portali społecznościowych omówione w: Tan i Phan, 2016.

zastosowania zaczną być osiągalne technicznie. Szczególnie obiecującą perspektywą jest zastosowanie tej technologii w ocenie wiarygodności kredytowej klientów w segmencie mikropożyczek online (Cnudde et al., 2015; Ruiz et al., 2017). Badania w tym kierunku są obecnie prowadzone między innymi w Stanach Zjednoczonych i Chinach (Williams, 2016).

Oczywiście tak szczegółowe profilowanie konsumentów musi budzić uzasadnione wątpliwości w zakresie zgodności z prawem ochrony danych. Należy jednak pamiętać, że przedstawione przez FTC dane dotyczą rynku amerykańskiego, na którym funkcjonują zdecydowanie mniej restrykcyjne zasady w zakresie gromadzenia i obrotu danymi osobowymi. Wysokie standardy ochrony danych obowiązujące w UE mają ograniczone zastosowanie w odniesieniu do przedsiębiorców prowadzących swoją działalność poza obszarem UE. Problem ten znajduje szerokie omówienie w literaturze, a w przypadku rynku *fintech* jest wskazywany jako potencjalna bariera dla rozwoju nowoczesnych usług finansowych przez przedsiębiorców europejskich.

Przenosząc powyższe rozważania na grunt przepisów krajowych, należy zauważyć, że według dominującego poglądu ocena zdolności kredytowej jest obowiązkiem, a nie tylko prawem, instytucji kredytującej (Stangret-Smoczyńska, 2016). Wniosek taki wynika wprost z treści art. 9 ustawy o kredycie konsumenckim. Z kolei na tle art. 70 ust. 1 ustawy – Prawo bankowe w literaturze wskazuje się, że postępowanie w przedmiocie ustalenia zdolności kredytowej musi poprzedzić zawarcie umowy kredytu, a jego celem jest zabezpieczenie banku przed ewentualnym zagrożeniem spłaty kredytu i innych opłat (Sikorski, 2015, teza 1 d art. 79). Praktyczne wykorzystanie SI w tym procesie wymagałoby prawnego uregulowania dwóch zagadnień: (1) możliwości zlecenia wykonania czynności oceny ryzyka kredytowego zewnętrznym podmiotom (outsourcing) oraz (2) modyfikacji zasad gromadzenia i przetwarzania danych na potrzeby oceny ryzyka kredytowego (problem danych nadmiarowych). W chwili obecnej krajowy prawodawca oddzielnie traktuje kwestie wykorzystania przez instytucję finansową zewnętrznych algorytmów analitycznych (outsourcing modelu analitycznego) oraz zewnętrznych baz danych.

Pierwszy z wymienionych obszarów dotyczy *stricte* banków – a nie wszystkich instytucji finansowych – i związany jest z obowiązującą treścią art. 6a ust. 3 pkt 1 prawa bankowego, zgodnie z którą bank nie może powierzyć podmiotowi zewnętrznemu wykonywania w jego imieniu podstawowych czynności bankowych, do jakich zaliczono ocenę zdolności kredytowej. Ograniczenie to powoduje, że ewentualne zastosowanie SI w procesie oceny ryzyka byłoby możliwe wyłącznie, gdyby system ten był własnością banku (a nie usługą świadczoną przez wyspecjalizowany podmiot zewnętrzny). Nie jest to przeszkoda uniemożliwiająca wdrożenie SI, jednak w praktyce może znacznie ograniczyć przydatność tej technologii. Jedną z podstawowych korzyści algorytmów uczenia maszynowego jest bowiem zdolność do analizowania dużych zbiorów informacji i szukania w nich zależności i powiązań. Ograniczenie zakresu danych wyłącznie do informacji pochodzących z jednej instytucji finansowej (banku) może zmniejszyć skuteczność analizy.

Istotniejszym ograniczeniem wydają się jednak być obowiązujące zasady gromadzenia i przetwarzania danych. Aby system SI mógł podejmować decyzje na podstawie danych z *Big Data* w zakresie zbliżonym do opisanego w raporcie FTC, zmodyfikowane musiałyby zostać zarówno regulacje sektorowe (prawo bankowe oraz ustawa o kredycie konsumenckim), jak i regulacje dotyczące ochrony danych (rozporządzenie UE 2016/679). W pierwszej kolejności należy zwrócić uwagę na art. 105a prawa bankowego, zgodnie z których przetwarzanie danych na potrzeby oceny



ryzyka kredytowego jest możliwe tylko w odniesieniu do klientów banku oraz tylko w określonych okolicznościach. W szczególności, jak wskazał WSA w Warszawie w wyroku z 12 lipca 2017 r., bank nie może przetwarzać danych zawartych we wniosku kredytowym w sytuacji, gdy nie doszło do zawarcia umowy kredytowej (WSA w Warszawie, 2017, II SA/Wa 2221/16). Choć ustawodawca w art. 105 a ust. 4 prawa bankowego przewidział możliwość przetwarzania informacji dotyczących wygasłych zobowiązań bez zgody kredytobiorcy na potrzeby metod i modelu wewnętrznej oceny ryzyka, to jednak zakres danych, które mogą być w ten sposób przetwarzane został istotnie ograniczony. W szczególności zgodnie z rozporządzeniem Ministra Finansów z 27 marca 2007 r. obejmuje on podstawowe dane osobowe, informację o miejscu pracy, sytuacji finansowej oraz rodzinnej, a także dane dotyczące zaciągniętych zobowiązań<sup>8</sup>. Polskie banki nie mają zatem prawnej podstawy do przetwarzania na potrzeby doskonalenia wewnętrznych modeli scoringowych dodatkowych, nieuwzględnionych w tym katalogu informacji – takich jak wskazane w omówionym wcześniej raporcie FTC. Ograniczenie to nie obejmuje innych instytucji finansowych, udzielających kredytów na podstawie ustawy o kredycie konsumenckim. W tym przypadku kredytodawca może dokonać oceny zdolności kredytowej w oparciu o „informacje pozyskane z odpowiednich baz danych” (art. 9 ust. 2 ustawy o kredycie konsumenckim). W ocenie M. Stanisławskiej „nie ma żadnych przeszkód prawnych, aby kredytodawca przy przeprowadzaniu oceny zdolności kredytowej konsumenta opierał się pomocniczo także na ocenie wiarygodności płatniczej konsumenta przeprowadzonej (za zgodą konsumenta) przez podmiot trzeci (na przykład przez innowacyjne podmioty branży *fintech*) w oparciu o dane dotyczące aktywności konsumenta w Internecie, w tym mediach społecznościowych czy dane dotyczące szkodowości w ubezpieczeniach”. Pogląd ten musi jednak budzić uzasadnione zastrzeżenia w zakresie, w jakim prowadzi do możliwości wykorzystania informacji o aktywności konsumenta w mediach społecznościowych w procesie podejmowania decyzji kredytowych. W takim przypadku uzasadnione byłoby bowiem sformułowanie zarzutu gromadzenia danych nadmiarowych, a więc takich, które nie są związane z celem przetwarzania (art. 5 ust. 1 pkt c rozporządzenia 2016/679). W rzeczywistości bowiem analityka *Big Data* programowo opiera się na gromadzeniu danych, które początkowo należy uznać za nadmiarowe (Rojszczak, 2019b, s. 416–417)<sup>9</sup>. Dopiero po pewnym czasie, wraz z postępami w analizie danych, odkrywane są nowe zależności i powiązania, które pozwalają wskazać, że określone kategorie gromadzonych informacji były potrzebne i związane z celem przetwarzania. Uwzględniając treść art. 5 ust. 2 rozporządzenia 2016/679, praktykę taką należy uznać za co najmniej ryzykowną z punktu widzenia administratora danych – prowadziłyby do trudności w wykazaniu spełnienia zasady minimalizacji danych. Nie ma natomiast formalnej przeszkody, aby instytucja finansowa, działając w oparciu o zgodę osoby, której dane dotyczą, skorzystała z zewnętrznej usługi *fintech* w procesie oceny ryzyka kredytowego – przy założeniu zachowania zasad wynikających z prawa ochrony danych.

<sup>8</sup> Por. § 3 rozporządzenia Ministra Finansów z 27.03.2007 r. w sprawie szczegółowego zakresu przetwarzanych informacji dotyczących osób fizycznych po wygaśnięciu zobowiązania wynikającego z umowy zawartej z bankiem lub inną instytucją ustawowo upoważnioną do udzielania kredytów oraz trybu usuwania tych informacji (DzU Nr 56, poz. 373).

<sup>9</sup> Zob. także opinię brytyjskiego organu właściwego w sprawie ochrony danych osobowych na temat stosowania zasady minimalizacji w odniesieniu do analityki *Big Data*: Information Commissioner's Office, 2017, 91.

## V. Wykrywanie nadużyć i transakcji podejrzanych

Jednym z bardziej perspektywicznych zastosowań SI w sektorze nowoczesnych usług finansowych jest obszar przeciwdziałania nadużyciom. Typowanie transakcji podejrzanych to element zapobiegania oszustwom na szkodę klientów, jak i samej instytucji, ale również ważny mechanizm przeciwdziałania praniu pieniędzy i finansowaniu poważnej przestępczości (w tym terroryzmowi). Tym, co odróżnia systemy uczenia maszynowego od klasycznych algorytmów typowania transakcji podejrzanych jest potencjał w wyszukiwaniu nowych, nieznanych wcześniej rodzajów nadużyć. Systemy uczenia maszynowego poprzez proces uczenia potrafią osiągać lepsze wyniki niż klasyczne algorytmy, dzięki czemu ich stosowanie może prowadzić do realnych korzyści finansowych podmiotów, które decydują się na ich wdrożenie. Jak jednak w każdym przypadku zastosowania SI, sukces wdrożenia warunkowany jest prawidłowym przeprowadzeniem etap nauki, a więc przygotowaniem odpowiednio dużego zestawu danych referencyjnych. Tylko w ten sposób możliwe jest osiągnięcie poziomu, przy którym algorytm będzie trafnie typował transakcje podejrzane przy jednocześnie akceptowalnym poziomie fałszywych alarmów (tzw. *false positive*)<sup>10</sup>. Proces optymalizacji działania tego typu algorytmów jest zadaniem czasochłonnym i wymagającym także wysokich kompetencji technicznych, stąd też ten segment zastosowań SI znajduje się w stałym zainteresowaniu podmiotów branży *fintech*.

W literaturze odnaleźć można analizy dotyczące możliwości wykorzystania algorytmów uczenia maszynowego do przeciwdziałania różnego typu oszustwom. Najbardziej oczywiste dotyczą wykrywania nadużyć w korzystaniu z określonych produktów finansowych – np. płatności kartowych lub mobilnych (Hoi i Le, 2018). W takim przypadku system SI może zostać przygotowany do wykrywania zdarzeń niestandardowych, dotyczących nie tylko przypadków korzystania z instrumentu płatniczego w sposób odmienny od typowego (analiza behawioralna), lecz także z wykorzystaniem informacji dodatkowych, pochodzących z innych baz danych. Przykładem może być np. zestawianie w czasie rzeczywistym informacji o lokalizacji punktu POS z geolokalizacją właściciela karty płatniczej (lokalizacją jego telefonu), co pozwala na potwierdzanie czy transakcji dokonuje uprawniona osoba. Przykładem implementacji tego modelu są mechanizmy antyfraudowe oferowane w ramach tzw. portfeli elektronicznych, stanowiących rodzaj nowoczesnej usługi płatniczej pozwalającej na gromadzenie różnych instrumentów płatniczych w ramach jednej usługi cyfrowej<sup>11</sup>.

W bardziej rozbudowanych zastosowaniach systemy wykrywania nadużyć mogą wykorzystywać indywidualne profile klienta do oceny czy realizowane transakcje są nie tylko zgodne z wcześniejszymi transakcjami realizowanymi przez tę samą osobę, lecz także zgodne z decyzjami zakupowymi podejmowanymi przez innych, podobnych klientów. W tym zakresie zastosowanie mogą znaleźć podobne profile konsumenckie, jak w przypadku oceny wskaźników kredytowych, z tą wszakże różnicą, że wykorzystanie tych mechanizmów wprost służyłoby interesom klien-

<sup>10</sup> Terminem *false positive* określane jest zjawisko błędnego klasyfikowania zdarzeń nieprawidłowych (uznawania ich za akceptowalne), natomiast jako *false negative* określane jest uznawanie za błędne przypadków prawidłowych. Wskaźniki *false positive* i *false negative* służą do oceny jakości algorytmów decyzyjnych. W statystyce stosowane są pojęcia „błędu pierwszego rodzaju” (*false positive*) oraz „błędu drugiego rodzaju” (*false negative*).

<sup>11</sup> Przykładem takiej usługi jest elektroniczny portfel oferowany przez Visa we współpracy z bankami. Analizując zapisy regulaminu takiej usługi, bez trudu można odnaleźć regulacje dowodzące stosowania przez usługodawców mechanizmów wykrywania nadużyć – por. np. pkt 4 ust. 5 ogólnych warunków korzystania z Portfela Elektronicznego ING oraz V.me by Visa: „system przeciwdziałania oszustwom serwisu V.me by Visa może dokonywać dodatkowych kontroli by zagwarantować, że stale utrzymywany jest najwyższy poziom zabezpieczeń”, [https://www.ing.pl/\\_files/asset\\_upload/item/1014415](https://www.ing.pl/_files/asset_upload/item/1014415) (dostęp: 1.04.2019).

ta i odbywało się za jego zgodą. Należy pamiętać, że tego typu systemy mogą być budowane wyłącznie przez podmioty mające dostęp do odpowiednio szczegółowych informacji na temat swoich klientów (banki, firmy ubezpieczeniowe, podmioty telekomunikacyjne).

Wykrywanie nadużyć z wykorzystaniem uczenia maszynowego to usługa, która już dzisiaj jest oferowana przez liczne podmioty branży *fintech*. Klientami tego typu usług są instytucje finansowe, ale również duże sklepy internetowe oraz wszyscy przedsiębiorcy pragnący zapewnić wiarygodność realizowanych transakcji online. Na rynku dostępne są usługi pozwalające na przykład w zaawansowany sposób weryfikować lokalizację użytkownika, w tym sprawdzać czy osoba składająca zamówienie online nie korzysta z technik ukrywania swojej tożsamości lub maskowania adresu IP<sup>12</sup>. W ten sposób budowany jest wskaźnik punktowy pozwalający firmom e-commerce identyfikować próby oszustwa w dużej liczbie przetwarzanych zamówień.

W przypadku instytucji finansowych obok wykrywania przypadków nadużyć dotyczących własnych klientów (np. próba posłużenia się cudzą kartą płatniczą) oddzielnym zadaniem jest również wykonywanie obowiązków prawnych związanych z obszarem AML (*Anti Money Laundering*, przeciwdziałanie praniu pieniędzy). Proces typowania transakcji podejrzanych oraz zgłaszania ich do wyznaczonego organu (wcześniej GIIF, obecnie Szef KAS) funkcjonuje w polskim porządku prawnym od niemal dwudziestu lat. Jego podstawę stanowi stosowanie środków bezpieczeństwa finansowego, których wykonywanie już zgodnie z ustawą z 16 listopada 2000 r. o przeciwdziałaniu praniu pieniędzy i finansowaniu terroryzmu<sup>13</sup> mogło być zlecane podmiotom zewnętrznym. We wcześniejszym stanie prawnym ustawodawca nie przewidział jednak możliwości outsourcingu tzw. wzmoczonych środków bezpieczeństwa (art. 9e ustawy z 16 listopada 2000). Fakt ten był wskazywany przez przedstawicieli branży *fintech* jako bariera dla rozwoju świadczonych przez nich usług (Komisja Nadzoru Finansowego, 2018, pkt 35). Wraz z wejściem w życie nowej ustawy o przeciwdziałaniu praniu pieniędzy i finansowaniu terroryzmu<sup>14</sup>, prawodawca rozszerzył przewidziany w art. 48 zakres powierzenia stosowania środków bezpieczeństwa finansowego, uwzględniając możliwość wykonywania przez podmiot trzeci obowiązków przewidzianych w art. 43 ust. 3, a dotyczących bieżącej analizy przeprowadzanych transakcji. W efekcie obecnie instytucje zobowiązane do stosowania przepisów ustawy mają większą swobodę w korzystaniu z ramach outsourcingu z innowacyjnych usług zewnętrznych, także w obszarze analizy transakcji i typowania transakcji podejrzanych.

Oddzielną kategorią systemów antyfraudowych są systemy dedykowane do identyfikacji nadużyć wewnętrznych, np. związanych z prowadzonymi procesami zamówień towarów i usług, rozliczania kosztów podróży służbowych, wykorzystania sprzętu i zasobów firmowych itp. Jest to stale rosnący segment usług, w przypadku których celem jest zmniejszanie zawyżonych kosztów lub oszustw dokonywanych przez własnych pracowników przedsiębiorcy.

O ile powyższe przykłady dotyczą systemów SI dedykowanych do zmniejszania ryzyka nadużyć finansowych na poziomie poszczególnych organizacji, to w podobny sposób możliwe jest typowanie transakcji podejrzanych na płaszczyźnie państwa. Wdrażane w wielu krajach – w tym

<sup>12</sup> Przykładem jest kanadyjska usługa GeoGuard, której dostawca wskazuje na przeprowadzanie ponad 400 testów antyfraudowych każdej transakcji dzięki czemu jest w stanie identyfikować i blokować 100.000 unikalnych użytkowników każdego miesiąca. Opis usługi: <https://www.geoguard.com/> (dostęp: 1.04.2019).

<sup>13</sup> DzU 2017, poz. 1049.

<sup>14</sup> Ustawa z dnia 1 marca 2018 r. o przeciwdziałaniu praniu pieniędzy i finansowaniu terroryzmu (DzU 2018, poz. 723).

także Polsce – systemy wymiany informacji o podatnikach, pozwalają również na identyfikowanie różnego typu nadużyć finansowych. Od 2018 roku w oparciu o znowelizowane przepisy ordynacji podatkowej<sup>15</sup> w Polsce funkcjonuje STIR (System Teleinformatyczny Izby Rozliczeniowej), gromadzący rozbudowane informacje na temat krajowych rachunków i operacji finansowych realizowanych za ich pośrednictwem. W debacie publicznej STIR jest prezentowany jako komponent e-państwa dedykowany do walki z poważną przestępczością, taką jak tzw. karuzele VATowe lub pranie pieniędzy. Ustawodawca planował dalsze rozszerzenie zakresu danych gromadzonych przez STIR o informacje dotyczące adresu IP, z którego zlecono operację finansową<sup>16</sup>. W ten sposób aparat skarbowy mógłby łatwo identyfikować powiązane ze sobą transakcje dotyczące wielu różnych podmiotów, a realizowane w podobnym czasie z tego samego komputera. Według dostępnych informacji obecnie system STIR funkcjonuje w oparciu o klasyczne reguły AML, nic nie stoi na przeszkodzie, aby w przyszłości olbrzymia baza danych systemu stała się materiałem treningowym przy wdrożeniu algorytmów uczenia maszynowego.

## VI. Robo-advisory w doradztwie inwestycyjnym

W ostatnich latach stale rośnie popularność częściowo lub całkowicie zautomatyzowanych usług doradztwa inwestycyjnego. W literaturze określa się je zbiorczo terminem *robo-advisory*, chociaż w zależności od użytego kontekstu przez pojęcie to mogą być rozumiane *de facto* różne usługi. Zgodnie z definicją stosowaną przez Komisję Nadzoru Finansowego, „robodoradztwo” to forma zautomatyzowanego doradztwa finansowego, opartego na zaawansowanych algorytmach, świadczonego z wykorzystaniem sztucznej inteligencji i narzędzi do analizy dużych zbiorów danych<sup>17</sup>. Z kolei FINRA (Financial Industry Regulatory Authority), amerykański podmiot powołany jako organ samoregulacji rynku, produkty tego typu określa jako „narzędzia cyfrowego doradztwa inwestycyjnego” (*digital investment advice tools*) i zalicza do nich także usługi automatycznych analiz inwestycyjnych oferowane dla tradycyjnych doradców inwestycyjnych (Financial Industry Regulatory Authority, 2016, s. 2). Robodoradztwo może być więc postrzegane jako samodzielna usługa zastępująca pracę doradcy inwestycyjnego (perspektywa KNF), może być także traktowana jako uzupełnienie narzędzi dostarczających aktualną informację dla wykwalifikowanego profesjonalisty. Dalsze różnice dotyczą zakresu samej usługi – a w szczególności czy algorytmizacji podlega wyłącznie analityka i dostarczenie rekomendacji, czy także składanie zleceń inwestycyjnych w imieniu inwestora. W tym drugim przypadku stosowany bywa także termin „handel algorytmiczny”<sup>18</sup>.

Korzyści ze stosowania robodoradztwa koncentrują się wokół zwiększania dostępu do nowoczesnych usług finansowych. Jak wskazuje KNF, robodoradztwo obniża koszty usług doradztwa finansowego, dzięki czemu usługi te mogą być dostępne dla szerszego grona klientów. Jednocześnie jednak dostępne analizy wskazują, że znaczna część inwestorów lepiej ocenia usługi świadczone przez tradycyjnych doradców – zarówno w zakresie dopasowania produktów

<sup>15</sup> Zob. art. 119zg i n. ustawy z dnia 29 sierpnia 1997 r. – Ordynacja podatkowa (t.j. DzU 2018, poz. 800).

<sup>16</sup> Zob. art. 1 pkt 6 projektu z 16 maja 2018 r. ustawy o zmianie ustawy – Ordynacja podatkowa, <https://cli.re/Ld72xd> (dostęp: 1.04.2019). Ostatecznie w ostatecznej wersji nowelizacji nie uwzględniono postulatu automatycznego gromadzenia w STIR informacji na temat adresów IP, wprowadzając zamiast tego możliwość żądania uzupełnienia tych danych przez instytucję finansową (por. art. 119zs § 1 pkt 4 ordynacji podatkowej). Dlatego adresy IP osób składających zlecenia przelewów i tak są gromadzone, ale nie w STIR tylko przez instytucje odpowiedzialne (np. banki, SKOKi).

<sup>17</sup> *Robodoradztwo*, KNF, [https://www.knf.gov.pl/dla\\_ryнку/fin\\_tech/robodoradztwo](https://www.knf.gov.pl/dla_ryнку/fin_tech/robodoradztwo) (dostęp: 1.04.2019).

<sup>18</sup> *Handel algorytmiczny*, KNF, [https://www.knf.gov.pl/dla\\_ryнку/fin\\_tech/handel\\_algorytmiczny](https://www.knf.gov.pl/dla_ryнку/fin_tech/handel_algorytmiczny) (dostęp: 1.04.2019).

do indywidualnych potrzeb, czytelności przekazywanych informacji, jak i trafności rekomendacji. Usługi automatyczne zostały ocenione lepiej tylko w jednej kategorii, jaką był niższy koszt ich świadczenia (Fisch, Labour i Turner, 2017, s. 12).

O skali sukcesu tego typu modelu biznesowego może świadczyć przykład Betterment, jednej z pierwszych platform służących dostarczaniu usług robodoradztwa finansowego szerokiemu gronu konsumentów, która po niespełna dziesięciu latach działalności – według danych na marzec 2019 r. – zarządzała kontami 400 000 klientów i aktywami w wysokości 16 mld USD<sup>19</sup>. W ślad za sukcesem Betterment, w Stanach Zjednoczonych powstało szereg kolejnych tego typu usług, przy czym własne platformy udostępniły także instytucje finansowe świadczące klasyczne usługi doradztwa inwestycyjnego, takie jak Charles Schwab, Fidelity Investments czy Bank of America (Strzelczyk, 2017, s. 55). Skala prowadzonej działalności wskazuje na rosnące znaczenie zautomatyzowanych usług doradztwa finansowego, ale prowadzi również do konieczności analizy ram prawnych, w jakich tego typu usługi są świadczone.

Doradztwo inwestycyjne jest sektorem tradycyjnie kojarzonym z usługami finansowymi i podlegającym szczegółowym regulacjom prawnym. Jest to działalność licencjonowana, nadzorowana i zastrzeżona dla określonych kategorii podmiotów, w tym firm inwestycyjnych (Komisja Nadzoru Finansowego, 2012, s. 1). Także zawód doradcy inwestycyjnego należy do grupy zawodów regulowanych, którego wykonywanie przysługuje osobom wpisanym na listę prowadzoną przez KNF<sup>20</sup>. Powstaje zatem pytanie, czy podmioty działające na rynku robodoradztwa finansowego powinny podlegać takim samym regulacjom, jak doradcy inwestycyjni. KNF odpowiedziało na to pytanie twierdząco, wskazując, że czynności polegające na przygotowaniu w oparciu o potrzeby i sytuację klienta rekomendacji dotyczącej m.in. kupna lub sprzedaży instrumentów finansowych – są doradztwem inwestycyjnym, a w efekcie stanowią działalność maklerską, której prowadzenie wymaga uzyskania odpowiedniej licencji. Nie każdy przykład wykorzystania algorytmów do generowania rekomendacji rynkowych (tzw. sygnałów inwestycyjnych) będzie traktowany jako wypełniający przesłanki usługi doradztwa inwestycyjnego. Kluczowe w tym przypadku jest uwzględnienie w rekomendacji indywidualnej sytuacji klienta (np. oczekiwanego horyzontu inwestycyjnego, akceptowalnego poziomu ryzyka itp.). Dlatego też KNF wskazuje, że jeżeli „sygnał inwestycyjny będzie zawierał jedynie wskazanie kierunku zachowania inwestycyjnego bez uwzględnienia profilu inwestycyjnego klienta, do którego rekomendacja jest adresowana, to wówczas będzie to rekomendacja o charakterze ogólnym, niewypełniająca przesłanek doradztwa inwestycyjnego” (Komisja Nadzoru Finansowego, 2013, s. 16).

Stosowanie tych samych narzędzi nadzorczych do usług świadczonych tradycyjnie oraz z wykorzystaniem systemów uczenia maszynowego może okazać się niewystarczające. W szczególności wydaje się, że obecnie funkcjonujący proces potwierdzania kompetencji doradców zupełnie nie przystaje do rynku SI. Problem jest widoczny przy próbie oceny prawidłowości funkcjonowania systemu algorytmicznego przed jego dopuszczeniem do eksploatacji. O ile w przypadku systemów informatycznych bazujących na stałych algorytmach przedmiotem analizy może być prawidłowość reguł decyzyjnych, o tyle z uwagi na specyfikę SI – podejście takie okaże się nieskuteczne. W ich bowiem przypadku walidacji powinien podlegać cały proces eksploatacji systemu: od

<sup>19</sup> *Robo-advisors With the Most Assets Under Management – 2019, Robo-Advisor Pros 2019*, <https://cli.re/gEv4Kz> (dostęp: 1.04.2019).

<sup>20</sup> Art. 126 ust. 3 ustawy z dnia 29 lipca 2005 r. o obrocie instrumentami finansowymi (DzU 2018, poz. 2286).

zaprojektowania, poprzez etap uczenia, na rozwoju i eksploatacji skończywszy. Wykonywanie zewnętrznego nadzoru nad takim systemem będzie wymagało zatem nie tylko odpowiedniej wiedzy w zakresie instrumentów finansowych, lecz także wysokich kompetencji technicznych. Problem ten, chociaż sygnalizowany w literaturze (Baker, Bellaert, 2018, s. 734), z uwagi na obecne zaawansowanie produktów z segmentu robodoradztwa (koncentrujących się w zdecydowanej większości na wąskim zakresie instrumentów finansowych, to jest funduszach ETF oraz rynku forex) nie jest dostrzegany jako potencjalna trudność przez samych regulatorów. Dlatego, według danych z września 2018 roku, w żadnym państwie UE nie prowadzono prac związanych z wprowadzeniem odrębnych regulacji adresowanych do rynku robodoradztwa (Joint Committee of the European Supervisory Authorities, 2018, s. 11).

## VII. Podsumowanie

Branża *fintech* w sposób naturalny związana jest z rozwojem sztucznej inteligencji, a podmioty w niej działające jako jedne z pierwszych nauczyły się monetaryzować korzyści wynikające z zastosowania algorytmów uczenia maszynowego. Według opublikowanych w 2018 roku danych, 65% ankietowanych menedżerów pracujących w sektorze usług finansowych dostrzegało potencjał leżący w nowoczesnych technologiach, takich jak sztuczna inteligencja, *blockchain* czy robotyzacja (Aitken, 2018). Z tych samych badań wynika jednak, że tylko 33% badanych wskazało, że te technologie są obecnie wdrażane w ich organizacjach. Przyczyn tej dysproporcji można poszukiwać zarówno w niedojrzałości technologii, ostrożnym podejściu instytucji finansowych, jak i istniejących barierach regulacyjnych. Bez wątplenia jednak widoczny jest trend postępującej automatyzacji w sektorze finansowym, który już obecnie skutkuje zmianami w świadczeniu istniejących usług oraz pojawianiem się nowych, innowacyjnych produktów finansowych.

Amerykańska Rada Stabilności Finansowej (FSB) w opublikowanym w 2017 roku raporcie wskazała na korzyści płynące z wdrożenia SI i *Big Data* tak dla rynków finansowych, instytucji na nim działających, jak i samych klientów (Financial Stability Board, 2017, s. 24–28). Dotyczą one aspektów finansowych (zmniejszenie kosztów działalności, wpływające na zwiększenie dostępności usług dla szerszego kręgu odbiorców) ale i jakościowych (możliwość przeprowadzania analiz niedostępnych wcześniej). FSB podkreśla przy tym możliwość oferowania usług dostosowanych do potrzeb i oczekiwań konkretnego klienta, z uwzględnieniem profilu jego zachowania oraz akceptowalnego ryzyka. Jednocześnie podkreślono, że nowe technologie to także nowe zagrożenia. Jako przykład Rada wskazała ryzyko nieuprawnionej dyskryminacji w procesie wyznaczania wskaźników kredytowych. Słusznie w tym miejscu zauważono, że w przypadku *Big Data* nawet formalny zakaz gromadzenia określonych kategorii danych (np. dotyczących rasy, wyznania, orientacji seksualnej) nie stanowi technicznej przeszkody dla algorytmów SI w ujawnieniu tych cech z wykorzystaniem innych danych dostępnych w procesie uczenia maszynowego (Rojszczak, 2019a, s. 117–124).

Odrębnym problemem wymagającym dogłębnego rozpoznania jest sposób nadzorowania funkcjonowania podmiotów *fintech*, świadczących nowoczesne usługi z wykorzystaniem SI i *Big Data*. Dominujący obecnie model – polegający na próbie zastosowaniu tradycyjnych narzędzi nadzorczych – wydaje się nieperspektywiczny. Istotną świadczenia usług finansowych jest *zaufanie* i *wiarygodność*. Czym innym jest zaufanie do konkretnego profesjonalisty, świadczącego

określoną usługę osobiście, a czym innym zaufanie do technologii, za której wdrożenie i eksploatację odpowiadają zespoły składające się nierzadko z setek osób.

Rozwój SI w obszarze usług finansowych jest również przedmiotem zainteresowania ze strony polskich władz. W 2018 roku Ministerstwo Cyfryzacji opublikowało raport „Założenia do strategii AI w Polsce”, w którym analizie poddano także wpływ rozwoju nowoczesnych technologii na sektor finansowy. W dokumencie przedstawiono rekomendacje związane z dopasowaniem przepisów krajowych do specyfiki SI i *Big Data*. Autorzy dużo uwagi poświęcili wyjaśnieniu, dlaczego model outsourcingu wynikający z prawa rynku finansowego jest archaiczny, a dalsze jego funkcjonowanie stanowi barierę dla wprowadzania SI do krajowych instytucji finansowych (Ministerstwo Cyfryzacji, 2018, s. 199–206). Pozytywnie należy także ocenić inicjatywę KNF powołania tzw. piaskownicy regulacyjnej, która umożliwia testowanie i rozwijanie innowacyjnych usług finansowych we współpracy ze środowiskiem *fintech* oraz regulatorem (Komisja Nadzoru Finansowego, 2018b).

W ostatnich latach uwaga opinii publicznej została zwrócona na pierwsze wdrożenia tzw. kredytu społecznościowego (*Social Credit System*, SCS) w Chinach<sup>21</sup>. SCE to grupa rozproszonych systemów informatycznych o lokalnym zasięgu, z których niektóre zarządzane są przed instytucje publiczne, a część przez podmioty prywatne. Ich wspólną cechą jest tworzenie tzw. czarnych list (*black list*), na których umieszczane są jednostki krytycznie oceniane przez władzę („społecznie niedostosowane”) – np. posiadające zaległości podatkowe czy karane za przestępstwa (Sithig i Siems, 2019, s. 12). Obniżenie wskaźnika SCS może wynikać również z podejmowanych aktywności społecznych, w tym politycznych. Możliwość ta ma być uzyskana między innymi dzięki analizie informacji publikowanych w Internecie (np. wpisy na portalach społecznościowych). Znaczna część SCS jest zarządzana ręcznie, dlatego medialne przedstawianie tej technologii jako praktycznego przykładu zastosowania SI jest nietrafne.

Z perspektywy rynku *fintech* interesującym przykładem SCS jest natomiast platforma o nazwie Kredyt sezamowy (*Sesame Credit*) zarządzana przez spółkę zależną od koncernu Alibaba. Kredyt sezamowy opiera się na wykorzystaniu dużych zbiorów danych pochodzących z różnych źródeł, co ma pozwolić tamtejszym dostawcom usług finansowych na uwzględnienie we wskaźnikach wiarygodności kredytowej nie tylko informacji dotyczących kredytobiorcy, lecz także osób znajomych. Co więcej wskaźnik Kredytu sezamowego ma wpływ także na inne codzienne aktywności, takie jak na przykład szczegółowość kontroli bezpieczeństwa przeprowadzanej na lotnisku, możliwość adoptowania psa ze schroniska czy nawet ocenę w portalach randkowych (Chen i Cheung, 2017, s. 361–362).

System oceny wiarygodności obywateli wdrażany w Chinach dopiero ewoluuje, jednak już dzisiaj może być analizowany jako przykład, w jaki sposób nowoczesne technologie mogą wpłynąć na kształt usług finansowych, ale w dalszej perspektywie także na przemiany społeczne – nie zawsze wzmacniając przy tym wartości demokratyczne państwa.

Dlatego też omówienie perspektyw zastosowania algorytmów sztucznej inteligencji oraz *Big Data* w sektorze usług finansowych nie może prowadzić do utraty z pola widzenia prawdziwego potencjału tych technologii, jakim jest możliwość poznania zwyczajów i zachowań nie tylko jednostek, ale i całych społeczeństw z nieznaną wcześniej precyzją. W efekcie mechanizmy

<sup>21</sup> Omawiając konstrukcję SCS należy pamiętać zarówno o odmienności chińskiego modelu prawnego od obowiązującego w Europie, ale również innej tradycji związanej z perypcją i rolą prywatności w stosunkach społecznych. Temat został omówiony szczegółowo w Chen, 2015, s. 265–276.

prawne stojące na straży sposobu wykorzystania tych informacji powinny być jednym z zagadnień nierozzerwanie związanych z dyskusją nad nowymi zastosowaniami SI i *Big Data* w gospodarce.

## Bibliografia

- Aitken, R. (2018). Global Financial Services Bullish On AI, The 'Disruptive Tech' Frontrunner. *Forbes*, 28 listopada. Pozyskano z: <https://cli.re/gRVrDD> (15.01.2020).
- Anderson, C. (2008). The End of Theory: The Data Deluge Makes the Scientific Method Obsolete. *Wired*. Pozyskano z: <https://www.wired.com/2008/06/pb-theory/> (15.01.2020).
- Baker, T. i Dellaert, B. (2018). Regulating Robo Advice Across the Financial. *Iowa Law Review*, 103, 734.
- Chen, Y. (2015). Privacy and Freedom of Information in China. *European Data Protection Law Review*, (4).
- Chen, Y. i Cheung, A. (2017). The Transparent Self Under Big Data Profiling: Privacy and Chinese Legislation on the Social Credit System. *Journal of Comparative Law*, (2). Pozyskano z: <http://dx.doi.org/10.2139/ssrn.2992537> (15.01.2020).
- Choi, D. i Le, K. (2018). An Artificial Intelligence Approach to Financial Fraud Detection under IoT Environment: A Survey and Implementation. *Security and Communication Network*. <https://doi.org/10.1155/2018/5483472> (15.01.2020).
- Federal Trade Commission. (2015). *Data Brokers: A Call for Transparency and Accountability*. Pozyskano z: <https://goo.gl/ig9tEp> (15.01.2020).
- Financial Industry Regulatory Authority. (2016). *Report on Digital Investment Advice*. Pozyskano z: <https://cli.re/GBpoAw> (15.01.2020).
- Financial Services User Group. (2016). *Assessment of current and future impact of Big Data on Financial Services*. Pozyskano z: <https://cli.re/gBo3xy> (15.01.2020).
- Financial Stability Board. (2017). *Artificial intelligence and machine learning in financial services. Market developments and financial stability implications*. Pozyskano z: <http://www.fsb.org/wp-content/uploads/P011117.pdf>, s. 24–28 (15.01.2020).
- Fisch, J., Labour, M. i Turner, J. (2017). *The Economics of Complex Decision Making: The Emergence of the Robo Adviser*. Pozyskano z: <https://cli.re/Gw3Mj1>, s. 12 (15.01.2020).
- Hutson, M. (2018). Hackers easily fool artificial intelligences. *Science*, (6399).
- Information Commissioner's Office. (2017). *Big data, artificial intelligence, machine learning and data protection*. Pozyskano z: <https://goo.gl/fSMffi> (15.01.2020).
- Joint Committee of the European Supervisory Authorities. (2018). *Joint Committee Report on the results of the monitoring exercise on 'automation in financial advice'*. Pozyskano z: <https://cli.re/GNj2EA> (15.01.2020).
- Komisja Nadzoru Finansowego. (2012). Stanowisko KNF z 21.03.2012 r. w sprawie świadczenia przez firmy inwestycyjne usług doradztwa inwestycyjnego. Pozyskano z: <https://cli.re/6zy5AK> (15.01.2020).
- Komisja Nadzoru Finansowego. (2013). Stanowisko KNF z 3.09.2013. Pozyskano z: <https://cli.re/gqjv3D> (15.01.2020).
- Komisja Nadzoru Finansowego. (2018). *Rekomendacje Zespołu roboczego ds. rozwoju innowacji finansowych (FinTech) w odniesieniu do listy określonych barier zawartych w raporcie końcowym – statusy realizacji prac*. Pozyskano z: <https://cli.re/GXaomA> (15.01.2020).
- Komisja Nadzoru Finansowego. (2018b). Urząd KNF uruchamia Piaskownicę regulacyjną KNF. *KNF*, 25 października. Pozyskano z: <https://cli.re/GYqYZ2> (15.01.2020).



- Maletic, J. i Marcus, A. (2019). Data Cleansing: A Prelude to Knowledge Discovery. W: O. Maimon, L. Rokach (red.), *Data Mining and Knowledge Discovery Handbook*. Boston: Springer.
- McGinnis, J. (2009–2010). Accelerating AI. *Northwestern University Law Review Colloquy*, 368–372.
- Ministerstwo Cyfryzacji. (2018). *Założenia do strategii AI w Polsce*. Pozyskano z: <https://cli.re/LKxvM8> (15.01.2020).
- Piesko, M. (2002). O subtelnej różnicy między słabą a mocną wersją sztucznej inteligencji na przykładzie tekstu Turinga. *Zagadnienia Filozoficzne w Nauce*, 93–102.
- Rojszczak M. (2019a). Definicja i granice prawnej ochrony prywatności w epoce analityki big data. *RPEiS*, (1).
- Rojszczak, M. (2019b). *Ochrona prywatności w cyberprzestrzeni z uwzględnieniem zagrożeń wynikających z nowych technik przetwarzania informacji*. Warszawa: Wolters Kluwer.
- Rojszczak, M. (2019c). Wpływ robotyzacji na rynek pracy i sektor ubezpieczeń społecznych. *Prawo i Zabezpieczenie Społeczne*, (7).
- Różanowski, K. (2017). Sztuczna inteligencja: rozwój, szanse i zagrożenia. *Zeszyty Naukowe Warszawskiej Wyższej Szkoły Informatyki*, 2.
- Ruiz, S., Gomes, P., Rodrigues, L. i Gama, J. (2017). Credit Scoring in Microfinance Using Non-traditional Data. *EPIA Conference on Artificial Intelligence*. [http://dx.doi.org/10.1007/978-3-319-65340-2\\_37](http://dx.doi.org/10.1007/978-3-319-65340-2_37) (15.01.2020).
- Selde, E. (2013). Study of credit scorecard using only Facebook data. *Big Data Scoring*, 12 lipca. Pozyskano z: <https://cli.re/g9rrKx> (15.01.2020).
- Sikorski, G. (2015). *Prawo Bankowe. Komentarz*. Warszawa: Wydawnictwo C.H. Beck.
- Sithigh, D. i Siems, M. (2019). The Chinese social credit system: A model for other countries? *European University Institute Working Paper LAW*, 01. Pozyskano z: <https://cli.re/GoWeBd> (15.01.2020)
- Stangret-Smoczyńska, A. (2016). Obowiązek oceny zdolności kredytowej. W: A. Stangret-Smoczyńska, *Zdolność kredytowa w ujęciu prawnym prawa polskiego*. Warszawa: Wydawnictwo C.H. Beck.
- Strzelczyk, B. (2017). Rise of the Machines: The Legal Implications for Investor Protection with the Rise of Robo-Advisors. *DePaul Business and Commercial Law Journal*, 1.
- Tan, T. i Phan, T. (2016). Social Media-Driven Credit Scoring: the Predictive Value of Social Structures. *Thirty Seventh International Conference on Information Systems*. Pozyskano z: <https://cli.re/LWM3vB> (15.01.2020).
- Turing, A. (1950). Computing Machinery and Intelligence. *Mind*, 433–460.
- Williams, A. (2016). How Facebook can affect your credit score, *Financial Times*, 25 sierpnia. Pozyskano z: <https://cli.re/GAYWzz> (15.01.2020).