

8.0

HIPERPERSONALIZACJA Z UŻYCIEM AI Z ZACHOWANIEM PRYWATNOŚCI UŻYTKOWNIKA

Izabella Krzemińska

Orange Polska

Jakub Rzeźnik

Szkoła Główna Handlowa w Warszawie

Streszczenie

Rozdział przedstawia koncepcję hiperpersonalizacji w kontekście przemysłu 5.0, kluczowe różnice między dawną a nową personalizacją oraz wyzwania związane z ochroną prywatności użytkowników. Szczególną uwagę poświęcono wyjaśnieniu trzech paradoksów prywatności i personalizacji, związanych z wysokim poziomem wiedzy płynącej z danych. Wyniki naszych badań wskazują na konieczność zrównoważenia zaawansowanej personalizacji z ochroną prywatności zarówno użytkowników produktów końcowych, jak i pracowników firm korzystających z hiperpersonalizacji. Proponujemy metodę projektowania systemów AI operujących na danych użytkownika i dokonujących analiz całkowicie na urządzeniu końcowym (na przykładzie smartfonów). Przedstawiamy także przegląd technologii AI stosowanych w hiperpersonalizacji oraz metod *privacy by design* i *edge computing*.

Słowa kluczowe: personalizacja, AI, hiperpersonalizacja, przemysł 5.0, odpowiedzialna AI, prywatność, dobrostan użytkownika, zrównoważony rozwój

Rozdział z monografii: Doligalski T., Kaszyński D. (red. nauk.), Sztuczna inteligencja w przedsiębiorstwach i gospodarce (AI Spring 2024), Warszawa 2025.

Monografia oferowana jest w swobodnym dostępie do pobrania na stronie AI Lab SGH.

Wprowadzenie

W ostatnich latach koncepcja przemysłu 5.0 wprowadza nową hierarchię celów, kładąc nacisk na zrównoważony rozwój i integrację technologii z ludzkimi aspektami pracy. Celem niniejszego rozdziału jest identyfikacja roli hiperpersonalizacji w przemyśle 5.0 oraz ustalenie wyzwań związanych z ochroną prywatności użytkowników. Istnieją już rozwiązania techniczne, które sprzyjają personalizacji doświadczeń użytkownika, opierając się na danych i ochronie prawa użytkowników do zachowania prywatności.

Koncepcja przemysłu 5.0 jest nowym konstruktem, warto przywołać więc jego definicję, stworzoną jako wypadkowa dwunastu innych definicji przez Kovari [2024, s. 270]: „Przemysł 5.0 koncentruje się na efektywnej współpracy człowieka z maszynami, aby zwiększyć elastyczność i zrównoważony rozwój, polegając na inteligentnych maszynach. Przemysł 5.0 opiera się na osiągnięciach przemysłu 4.0, ale zamiast zastępować ludzi, ma na celu wykorzystanie potencjału ludzkiej inteligencji w interakcji człowiek – maszyna bardziej niż kiedykolwiek wcześniej. Pozwoli to ludziom wykorzystać swoje zdolności poznawcze i szybką adaptację do poprawy bez poświęcania dokładności i spójności oferowanych przez inteligentne maszyny. W ten sposób przemysł 5.0 koncentruje się na wpływie ekonomicznym, środowiskowym i społecznym, aby dokonywać zrównoważonych wyborów”¹.

W przemyśle 5.0 uczymy się i redefiniujemy cele na bieżąco, zmieniając akcenty i umieszczając człowieka w centrum transformacji. Głównym czynnikiem wpływającym na zmianę priorytetów jest upowszechnienie sztucznej inteligencji (*artificial intelligence*, AI) oraz pojawiające się wyzwania prawne, etyczne, społeczne. Wersja 4.0, odpowiadając na potrzeby przedsiębiorstw typu lean, takie jak eliminacja marnotrawstwa, zwiększenie efektywności, standaryzacja procesów, szybkie reagowanie na zmiany oraz ciągłe doskonalenie się, promowała automatyzację i dostosowywanie się do potrzeb użytkownika/klienta [Trzcieliński, 2020]. Z kolei przemysł 5.0 uzupełnia te potrzeby i rozszerza rozumienie człowieka w centrum zainteresowania o pracowników, podkreślając potrzebę współpracy między inteligentnymi systemami oraz zrównoważenie potrzeb ludzi (pracowników, użytkowników, konsumentów), a nie przedsiębiorstw.

¹ Oryginalne cytowanie z artykułu w języku angielskim (tłumaczenie własne): “Industry 5.0 focuses on effective human co-work with machines to increase flexibility and sustainability by relying on smart machines. Industry 5.0 builds on the achievements of Industry 4.0, but rather than replacing humans, it aims to exploit the potential of human intelligence in human-machine interaction more than ever before. This will allow people to use their cognitive abilities and rapid adaptability to improve without sacrificing the accuracy and consistency offered by intelligent machines. In this way, Industry 5.0 focuses on economic, environmental and social impact to make sustainable choices”.

To przewartościowanie w przemyśle 5.0 odpowiada na pojawiające się wyzwania związane z integracją nowych technologii z ludzkimi aspektami pracy, zapewnieniem bezpieczeństwa i etyki danych oraz zrównoważonego rozwoju i adaptacji infrastruktury. Zakłada też nieustanną adaptację jako kluczowy czynnik zrównoważonego rozwoju, gdzie znaczącą rolę w tej przemysłowej ewolucji odgrywają coraz to nowsze technologiczne innowacje [Nahavandi, 2019; Piccarozzi, Silvestri, Silvestri, Ruggieri, 2024].

Z kolei wzrastające możliwości techniczne oraz rosnąca potrzeba personalizacji już nie tylko produktów i usług, ale też doświadczeń użytkowników sprawiają, że coraz częściej mówi się o hiperpersonalizacji. Dużym wyzwaniem staje się osiągnięcie równowagi pomiędzy personalizacją użytkownika a prywatnością. Jeszcze większym wyzwaniem jest elastyczność w sytuacji zacierających się granic wobec tego, co uznać za korzyść, a co za szkodliwość [Finck, 2021; Solove, 2020; Zuboff, 2023] wraz z rosnącą wrażliwością dotyczącą danych cyfrowych [Graepel, Kosinski, Stillwell, 2013].

Dawna personalizacja skupiała się na dostosowywaniu produktów do szerokich grup użytkowników, opierając się na analizie danych demograficznych i ogólnych charakterystykach. Współczesna hiperpersonalizacja dzięki zaawansowanym technologiom umożliwia dostarczanie spersonalizowanych rozwiązań na podstawie szczegółowych danych zebranych w czasie rzeczywistym, tworząc unikalne doświadczenia użytkowników i przewidując ich przyszłe potrzeby. Ta współczesna koncepcja znacząco różni się od dawnych metod personalizacji opartych na poszukiwaniu cech typowych dla grup, co pokazano w tabeli 8.1. Dzięki zaawansowanym technologiom, takim jak sztuczna inteligencja i big data, możliwe jest dostosowywanie produktów do indywidualnych potrzeb użytkowników w czasie rzeczywistym. Podczas gdy tradycyjna personalizacja była ograniczona do grup użytkowników o wspólnych cechach, hiperpersonalizacja koncentruje się na jednostkowych preferencjach, bazując na szczegółowej analizie danych z wielu źródeł. Teraz przestaliśmy tworzyć produkty o konkretnych cechach a zaczęliśmy tworzyć automatycznie adaptowalne doświadczenia użytkownika [Kovari, 2024; Kuksa, Skinner, Fisher, Kent, 2022]. Następuje zwrot w kierunku złożonych algorytmów, które na podstawie danych przewidują potrzeby użytkowników, wykorzystują ich zachowania, ich zaangażowanie w czasie rzeczywistym, a nawet reakcje emocjonalne, aby dostroić interakcje i oferty. Technologia umożliwia przejście od doświadczeń typowych dla segmentów do prawdziwie zindywidualizowanych, gdzie segmentów jest tyle, ilu użytkowników.

Hiperpersonalizacja usług wymaga kolejnego przesunięcia akcentów i wyznaczonych priorytetów dla firm – z wysokiej produktywności i zaawansowania technologicznego w stronę zorientowania się na dopasowanie do klientów jako domyślnej

strategii. Konsekwencją takiej postawy jest zmiana ośrodka zarządzania technologią, gdzie to docelowy użytkownik staje się jej kontrolerem i wykorzystuje narzędzia dostarczane przez przemysł 5.0 z korzyścią dla własnego dobrostanu [Alves, Gaspar, Lima, 2023]. Oprócz indywidualnych zysków to nowe podejście powinno wzmacniać zarówno rozwój ludzi, współpracę między nimi, jak i kooperację między użytkownikami a maszynami.

Tabela 8.1. Porównanie dawnej i obecnej personalizacji

Cecha	Dawna personalizacja	Nowa hiperpersonalizacja
Zasięg	oparcie segmentacji na typowych użytkownikach różnie zdefiniowanych grup np. według zmiennych demograficznych	dopasowanie do jednostkowych preferencji z wykorzystaniem dostępnych cyfrowych danych
Technologia	ograniczone narzędzia analizy danych (ankiety, badania)	zaawansowane narzędzia: AI, big data, uczenie maszynowe
Dane	dane demograficzne, historyczne, zbiorcze	dane behawioralne, w czasie rzeczywistym, wielokanałowe
Zakres personalizacji	ograniczona, powierzchowna w celu uchwycenia najbardziej typowego zakresu cech, statystyczna	głęboka, precyzyjna, indywidualna, ograniczona tylko dostępem do danych
Sposób dostosowania	reaktywne: dostosowanie na podstawie przeszłych zachowań, najczęściej zachowań dla grupy	proaktywne: przewidywanie przyszłych potrzeb z uwzględnieniem kontekstu sytuacyjnego w czasie rzeczywistym
Cele	maksymalizacja zaspokojenia potrzeb grup docelowych	tworzenie unikalnych, personalizowanych doświadczeń, adaptowanych w czasie rzeczywistym
Interakcja z użytkownikiem	rzadka, mało dynamiczna	częsta, dynamiczna, w czasie rzeczywistym
Zakres zbieranych danych	ograniczony do kilku zmiennych (wiek, płeć, użycie produktu)	wielowymiarowe dane: lokalizacja, nawyki, preferencje, dane z wymiany społecznej, poglądy
Źródła danych	ankiety, dane transakcyjne	dane z mediów społecznościowych, aplikacji, internet rzeczy (IoT)

Źródło: opracowanie własne.

8.1. Hiperpersonalizacja i paradoksy prywatności

Hiperpersonalizacja, będąca rozwinięciem personalizacji, polega na technologicznym dostosowaniu produktów i usług do indywidualnych potrzeb użytkowników na skalę większą niż kiedykolwiek wcześniej. Technologie AI, takie jak Machine Learning i analityka predykcyjna, odgrywają kluczową rolę w hiperpersonalizacji [Kuksa i in., 2022; Schrage, 2014]. Algorytmy przewidujące potrzeby użytkowników

na podstawie analizy zachowań i reakcji emocjonalnych mogą dostroić interakcje i oferty w czasie rzeczywistym.

Przykłady zastosowania tych technologii obejmują personalizowane rekomendacje produktów, dynamiczne dostosowywanie interfejsów użytkownika oraz zindywidualizowane kampanie marketingowe.

Personalizacja w cyfrowym świecie wymaga zaawansowanej analizy danych użytkowników, łącząc dostosowanie produktu, usługi doświadczeń z maksymalizacją satysfakcji użytkowników, stąd też liczne wyzwania związane z prywatnością, etyką i ochroną danych. Prowadzi też do paradoksów, trudnych do rozwiązania dotychczasowymi metodami. Obszerne publikacje autorów i autorek, takich jak Finck [2021], Solove [2020], Zuboff [2023], dotyczące pojawiających się paradoksów doprowadziły do szerokiej dyskusji i trendu poszukiwania metod, które im przeciwdziałają i wymagają omówienia w kontekście prezentowanego rozwiązania.

Hiperpersonalizacja z założenia wymaga użycia danych o użytkowniku, traktowanych często jako dane wrażliwe, co budzi obawy dotyczące ochrony prywatności. I chociaż obecne trendy w technikach personalizacji wskazują na odwrót od zasad gromadzenia dużych ilości danych (big data) w kierunku minimalizacji przetwarzania, to jednak dalej dotyczą one danych niosących za sobą duży potencjał informacji o użytkowniku lub pracowniku. Z kolei Finck [2021] pisze o paradoksie regulacyjnym. Przepisy takie jak RODO mają na celu ochronę prywatności użytkowników, ale często nie nadążają za szybkim postępem technologicznym. Technologie rozwijają się szybciej niż regulacje, które są tworzone reaktywnie, co prowadzi do luk prawnych i trudności w skutecznej ochronie ludzi. Firmy muszą więc na bieżąco dostosowywać swoje praktyki do zmieniających się przepisów, co bywa skomplikowane i kosztowne, oraz powinny angażować użytkowników w dialog dotyczący użycia ich danych [Velasco, Reinoso-Carvalho, Escobar, Gustafsson, Petit, 2024].

Trzeci paradoks stanowi możliwość późniejszego wykorzystania danych do celów, na które użytkownicy pierwotnie nie wyrazili zgody [Finck, 2021]. W miarę rozwoju technologii i pojawiania się nowych możliwości biznesowych dane zebrane w jednym kontekście mogą być używane w innym, co może naruszać zaufanie użytkowników i prowadzić do problemów prawnych. Przykładem może być użycie danych zebranych podczas zakupów online do tworzenia szczegółowych profili konsumentów bez ich wiedzy i zgody, a używanych w dowolnym celu łącznie z ich odsprzedażą [Zuboff, 2023].

Wprowadzenie hiperpersonalizacji wiąże się także z wyzwaniami etycznymi. Firmy muszą podejmować decyzje dotyczące tego, jak dalece mogą ingerować w prywatność użytkowników w imię lepszego dostosowania usług. Istnieje ryzyko, że nadmierna personalizacja może prowadzić do uzależnień lub potencjalnej alienacji klientów, co

może negatywnie wpłynąć na ich zdrowie psychiczne i poczucie autonomii [Kuksa i in., 2022]. Dlatego kluczowym elementem zarządzania prywatnością w kontekście hiperpersonalizacji jest edukacja użytkowników. Powinni być świadomi, jakie dane są zbierane, w jaki sposób się je wykorzystuje i jakie mają prawa w zakresie ochrony swoich danych. Transparentność i jasna komunikacja ze strony firm są niezbędne do budowania zaufania i zapewnienia, że użytkownicy czują się bezpiecznie, korzystając ze spersonalizowanych usług [Pöttsch, 2009].

8.2. Poszukiwanie rozwiązania

Jedną z prób sprostania tym wyzwaniom jest koncepcja *privacy by design*, czyli prywatności uwzględnianej jako priorytet już na etapie projektowania technologii. Prywatność staje się integralnym i nienegocjowalnym elementem całego procesu tworzenia technologii, co zapewnia ochronę danych na każdym etapie ich przetwarzania [Cavoukian, 2012; Rocha, Silva, Dias, 2023]. Strategia minimalizacji danych, czyli gromadzenie tylko tych danych, które są niezbędne do realizacji określonych celów, również odgrywa kluczową rolę w ochronie prywatności użytkowników. Kolejnym filarem zwiększającym ochronę i kontrolę nad danymi jest przetwarzanie danych na urządzeniu użytkownika (*edge computing*) zamiast przesyłania ich do centralnych serwerów [Lin i in., 2024]. Minimalizuje to ryzyko wycieku danych i pozwala na szybsze przetwarzanie informacji.

Poszukiwane rozwiązanie nie mogło polegać na dotychczasowych schematach personalizowania usług, czyli rozciągniętym w czasie gromadzeniu wszelkich dostępnych informacji o zachowaniu użytkownika (np. śledzeniu odwiedzanych stron internetowych) lub przetwarzaniu i analizowaniu danych z historii używania smartfona (co ma miejsce np. w aplikacjach bankowych, sieciach społecznościowych, platformach streamingowych).

Zaproponowanym konceptem odpowiadającym na wyzwanie ochrony prywatności użytkownika w modelu *privacy by design* była idea predykcji profilu osobowości przy użyciu modelu *machine learning* już w momencie uruchomienia usługi cyfrowej, na podstawie danych dostępnych od momentu instalacji. Oprócz korzyści dla użytkowników w postaci zachowania prywatności (brak gromadzenia danych), takie rozwiązanie dawałoby przedsiębiorstwom możliwość zaoferowania personalizacji od pierwszego kontaktu z usługą. Dodatkowy benefit stanowi także możliwość użycia profilu użytkownika niezależnie od częstotliwości korzystania z usługi. Kolejnym wymaganiem dla poszukiwanego rozwiązania była pełna automatyzacja przewidy-

wania cech użytkownika, decydujących o jego potrzebach i preferencjach. Ze względu na możliwość zróżnicowanego udzielania zgód na dostęp do chronionych danych (lub brak takiej zgody) model predykcyjny musiał także brać pod uwagę wszystkie możliwe kombinacje dostępu do danych na urządzeniu końcowym.

Dodatkowo profil stworzony w wyniku chwilowego przetwarzania danych dostępnych podczas instalacji aplikacji byłby sam w sobie zminimalizowany, określając tylko te cechy, których poziom zdefiniowany jako niski (poniżej dwóch odchyłeń standardowych od średniej) i wysoki (powyżej dwóch odchyłeń standardowych od średniej) wskazywałby na szczególne i statystycznie różne potrzeby użytkownika. Zakładamy, że nie ma potrzeby specjalnego dostosowywania usługi dla użytkowników o przeciętnych potrzebach, zazwyczaj to właśnie dla nich tworzone i projektowane są usługi. Proponowana personalizacja skupia się na użytkownikach o potrzebach innych niż typowe, np. skrajnych introwertykach, którzy potrzebują znacznie mniej stymulacji i bodźców, oraz skrajnych ekstrawertykach, którzy potrzebują więcej stymulacji niż przeciętny użytkownik. Podobna zasada dotyczyłaby wszystkich cech, które byłyby przewidywane w modelu.

8.3. Budowanie i testowanie rozwiązania

135

Metodologią zastosowaną w przeprowadzeniu badania było Design Science, zaproponowane przez Hevner i Chateerjee w 2012 r. Postuluje ono postępowanie w trzech iteracyjnych cyklach: odpowiedniości, rygoru i projektowania artefaktów [Peffer i in., 2007]. Pierwszym krokiem jest identyfikacja problemu i motywacji do przeprowadzenia badania nad rozwiązaniem. W kolejnym etapie weryfikuje się potencjalną użyteczność artefaktów w stosunku do istniejącej bazy wiedzy. Następnie definiuje się cele dla rozwiązania i projektuje oraz rozwija docelowe rozwiązanie. Kolejnym krokiem jest ocena artefaktów, mierząca ich efektywność, a następnie ostateczne wyniki są komunikowane właściwym interesariuszom [Venable, Pries-Veje, Baskerville, 2016].

Proces badawczy rozpoczął się od wyboru koncepcji personalizacji i oparciu jej na cechach osobowości użytkowników. W obszarach badań związanych ze śladami cyfrowymi popularnym i wielokrotnie zweryfikowanym modelem osobowości jest *big 5* [Krzemińska, Rzeźnik, 2021]. Pięć wielkich czynników osobowości to: otwartość na doświadczenie (tolerancja wobec nowego i nieznanego), sumienność (znoszenie niepewności i chaosu), ekstrawersja (tolerancja na wysoką ilość bodźców i potrzeba socjalizacji), ugodowość (skupienie na potrzebach innych i chęć współpracy), stabilność emocjonalna (znoszenie stresu) [Costa, McCrae, 1992].

Kolejnym etapem było przeprowadzenie badań jakościowych, weryfikujących zróżnicowanie korzystania z usług cyfrowych oraz identyfikacja potrzeb użytkowników w zależności od profilu osobowości, wyznaczanego kwestionariuszem IPIP-50. Następnie w standardowej procedurze psychometrycznej utworzono własne narzędzie do przeprowadzenia testu osobowości. W dalszej kolejności powstała aplikacja na smartfony z systemem Android, w której połączone zostały dwie funkcje – wypełnianie testu osobowości oraz zbieranie i przetwarzanie danych użytkowników aplikacji. Kategorie analizowanych danych to: dane telekomunikacyjne (np. historia połączeń telefonicznych, wysyłania wiadomości tekstowych), ustawienia telefonu (np. jasność ekranu, wielkość tekstu na ekranie, poziom baterii), dane statystyczne dotyczące zdjęć (np. kolorystyka, liczba wykrytych twarzy, tryb czarno-biały) oraz dane dotyczące zainstalowanych aplikacji (np. lista aplikacji, częstość ich użycia).

Tabela 8.2. Miary jakości modelu predykcji osobowości uzyskane w badaniu

Cecha osobowości	Dokładność [accuracy]	F1
Otwartość	0,73	0,68
Sumienność	0,69	0,62
Ekstrawersja	0,76	0,73
Ugodowość	0,72	0,63
Stabilność emocjonalna	0,69	0,62

Źródło: opracowanie własne.

Pozyskiwanie i analizowanie danych zostało przeprowadzone na ponad 5000 uczestników płatnego panelu badawczego, którzy zostali poinformowani o zbieraniu anonimowych danych (bez łączenia z jakimikolwiek identyfikatorami) oraz udzielili niezbędnych zgód na dostęp do danych przed rozpoczęciem korzystania z aplikacji. Ostatecznie zebrano ponad 200 zmiennych różnego rodzaju, które po połączeniu z wynikiem testu osobowości zostały na późniejszym etapie wykorzystane w tworzeniu modelu predykcyjnego. Model machine learning przewidujący profil osobowości został wytrenowany przy użyciu bibliotek *scikit-learn*, *pandas*, *numpy*. Ewaluacja jakości modelu nastąpiła poprzez użycie metryk *accuracy*, *precision* i *F1 score* na zbiorze testowym oraz poprzez walidację krzyżową. Wyniki, przedstawione w tabeli 8.2, pozwalają na stwierdzenie, że stworzony przez uczenie maszynowe model, przewidujący profil osobowości, osiągnął trafność (*accuracy*) 0,76 dla ekstrawersji. To wskazuje na wysoką skuteczność modelu w przewidywaniu potrzeb użytkowników na podstawie danych z ich urządzeń mobilnych. Nieco niższe wyni-

ki osiągnięto dla pozostałych cech, w tym najniższe dla sumienności i stabilności emocjonalnej (0,69 i 0,62 odpowiednio). Oznacza to, że model przewidywania osobowości wypracowany w badaniu osiągnął lepsze wyniki niż benchmark utworzony z 14 badań predykcji ze *state-of-the-art* (gdzie średnia dla cech z najwyższym *accuracy* wyniosła 0,69, a średnia dla wszystkich cech: 0,643), ustępując jedynie modelowi korzystającemu ze śledzenia ruchów gałek ocznych (tu osiągnięto *accuracy* 0,85), jak wykazuje Krzemińska [2022]. Procedura tworzenia modelu według metodologii Design Science została szczegółowo opisana w pracy doktorskiej autorki niniejszego rozdziału [Krzemińska, 2022].

Po wytrenowaniu i walidacji modelu predykcyjnego, działającego na danych ze smartfonów, możliwe stało się utworzenie osobnego artefaktu – biblioteki systemu Android. Dzięki temu w każdą aplikację na telefony mobilne z powyższym systemem może zostać wbudowany komponent przewidujący profil klienta. Jest to możliwe dzięki wytrenowaniu modelu predykcyjnego na danych dostępnych od momentu instalacji oraz połączeniu ich z wynikami testu osobowości. W przypadku nowych klientów model oczywiście nie zna profilu ich osobowości, ale jest w stanie go przewidywać na podstawie swojego treningu. Testy techniczne wykazały, że czas przetwarzania danych lokalnie i określenia osobowości klienta wynosi poniżej jednej sekundy. Aplikacje korzystające z tego typu personalizacji mogą więc dopasować swój wygląd i funkcjonalności do użytkownika już w trakcie pierwszego uruchamiania. Unikalną cechą tego rozwiązania jest to, że wszystkie obliczenia odbywają się na urządzeniu użytkownika, a dane nie są przesyłane na zewnątrz, co chroni prywatność. Sugeruje to rozwiązanie dla trzech przywoływanych wcześniej paradoksów prywatności:

1. Pożądane przez użytkowników dostosowanie usługi do ich indywidualnych potrzeb ma miejsce na urządzeniu końcowym (w tym przypadku na smartfonie) na podstawie jednorazowego, lokalnego dostępu aplikacji, na który wyrażają zgodę.
2. Nawet w sytuacji, gdy regulacje prawne nie nadążają za postępem technologicznym, przedsiębiorstwo dostarczające aplikację z komponentem personalizującym w sposób zachowujący prywatność nie ma dostępu do danych, dzięki którym dokonywana jest indywidualizacja produktu. Nie ma więc możliwości wnioskowania czegoś o kliencie z danych, które nie są objęte regulacjami.
3. W proponowanym rozwiązaniu nie istnieje przechowywanie danych, nie ma zbierania historii działań użytkownika. Oznacza to, że dane nie mogą zostać użyte w późniejszym terminie do zastosowań, na które użytkownicy nie wyrazili zgody.

8.4. Dyskusja

Era paradoksów prywatności wymaga szczególnego zrozumienia potencjału i pułapek technologii personalizacji. Nasze badania wskazują na konieczność dalszej eksploracji potencjału *privacy by design* oraz *edge computing* w kontekście hiperpersonalizacji. Przyszłe badania powinny skoncentrować się na rozwijaniu narzędzi AI, które łączą zaawansowaną personalizację z ochroną prywatności, oraz na analizie długoterminowych skutków takich technologii dla użytkowników. Spersonalizowane doświadczenia mogą znacznie zwiększyć zaangażowanie i satysfakcję użytkowników, ale nie powinny odbywać się kosztem naruszenia prywatności. Zrównoważenie tych aspektów wymaga solidnych rozwiązań technologicznych, rygorystycznych przepisów oraz zmiany podejścia do danych użytkowników i w konsekwencji zmiany w podejściu biznesowym. Poszanowanie prywatności i autonomii użytkowników w przemyśle 5.0 powinno być priorytetem.

Rozwiązania podobne do zaproponowanych w rozdziale nie mogą być wdrażane bez uprzedniej dokładnej i uczciwej analizy korzyści użytkowników i biznesu. Świadomość zagrożeń pojawiających się przy stosowaniu personalizacji [Zuboff, 2023] powinna doprowadzić do uzupełnienia technologii o mechanizmy chroniące użytkownika, np. zapobiegające uzależnieniu lub nieświadomej utracie kontroli i autonomii.

Niewątpliwie dalszych skrupulatnych i pogłębionych badań wymagają zarówno biznesowe ograniczenia personalizacji, jak i te związane z ograniczeniami samego użytkownika. Myśląc o ograniczeniach biznesowych, można stawiać pytania: Czy personalizacja ma granice? Czy personalizując w sposób prawie doskonały i zindywidualizowany wszystkie usługi cyfrowe, doprowadzimy do sytuacji, w której personalizacja wyczerpie swój korzystny potencjał? Czy istnieją jakieś alternatywy? Z kolei myśląc o ograniczeniach ze strony użytkownika, należy rozważyć i dobrze przebadać aspekty związane z różnym poziomem potrzeb w zakresie personalizacji, poczucia znudzenia lub zagrożenia nadmierną ilością wiedzy o użytkowniku lub takim poziomem personalizacji, który zaczyna użytkownikowi zagrażać (uzależnienie, zbyt duża atrakcyjność cyfrowych doświadczeń). Oddzielnym aspektem wymagającym dalszych badań jest ryzyko braku rozwoju poznawczego i emocjonalnego w przypadku nadmiernego dostosowywania się lub nawet ryzyka braku potrzeby socjalizacji – bo człowiek, mając własne autonomiczne cele, nie osiągnie takiego poziomu adaptacyjności, jak potencjalnie może osiągnąć model oparty na sztucznej inteligencji. To ostatnie z kolei jest wyzwaniem społecznym, bo sprzyja rosnącej samotności.

Prezentowane rozwiązanie, choć realizuje cele związane z prywatnością oraz oszczędnym korzystaniem z zasobów (minimalizacja ilości danych i przetwarzania),

wymaga rozwiązań uzupełniających, związanych ze skalowalnością oraz opracowaniem mierników jakości danych do stworzenia modelu oraz jakości samego uzyskanego profilu. Powinno być wzbogacone o ocenę zaufania do obu tych czynników. Stanowi to poważne wyzwanie w sytuacji braku gromadzenia danych oraz zachowania prywatności danych. Istnieje już szereg prac badawczych w obszarze *federated analytics* i *federated learning*, których celem jest budowa rozwiązań dedykowanych wymianie niezbędnych informacji przy zachowaniu prywatności [Liu i in., 2024].

Podsumowanie

W kontekście przemysłu 5.0 kluczowym wyzwaniem jest znalezienie równowagi między zaawansowaną personalizacją a ochroną prywatności użytkowników. Nasze badania wskazują, że zastosowanie koncepcji *privacy by design* oraz strategii minimalizacji danych może skutecznie adresować te wyzwania. Proponowane rozwiązanie, polegające na lokalnym przetwarzaniu danych, minimalizacji zbieranych informacji oraz integracji ochrony prywatności już na etapie projektowania, zapewnia wyższą jakość spersonalizowanych usług oraz gwarantuje bezpieczeństwo danych użytkowników.

Jednym z przyszłych kierunków rozwoju technologii personalizacji w przemyśle 5.0 jest wykorzystanie *federated learning*. Podejście to pozwala na trenowanie modeli AI bez konieczności centralizowania danych użytkowników. Dzięki temu modele mogą być aktualizowane na podstawie danych lokalnych, bez gromadzenia danych trenujących, co zwiększa poziom ochrony prywatności, minimalizuje ryzyko wycieku informacji oraz pozwala na ciągłe doskonalenie algorytmów.

Dodatkowo *federated analytics* może być stosowane do monitorowania aktualności wykorzystywanych modeli bez narażania prywatności użytkowników. Dzięki temu firmy mogą na bieżąco oceniać efektywność personalizacji i wprowadzać niezbędne poprawki, co zapewnia utrzymanie usług wysokiej jakości.

Przyszłe badania powinny koncentrować się na dalszym rozwijaniu technologii *federated learning* i *federated analytics*, a także na analizie ich wpływu na ochronę prywatności i jakość spersonalizowanych usług. Dalszy rozwój tych technologii, w połączeniu z edukacją użytkowników w zakresie ochrony ich danych, będzie kluczowy dla sukcesu przemysłu 5.0 i zapewnienia zrównoważonego rozwoju technologii personalizacji.

W przyszłości dalszy rozwój technologii przemysłu 5.0 powinien koncentrować się na edukacji użytkowników (komunikacja korzyści i zagrożeń związanych z personalizacją), rozwoju technologii sprzyjających ochronie prywatności oraz harmonizacji

technologicznych innowacji z wartościami społecznymi i etycznymi. Podobne rozwiązania będą stanowiły istotne wsparcie dla realizacji celów przemysłu 5.0.

Prezentowane rozwiązanie zapewnia nie tylko wyższą jakość spersonalizowanych usług, ale również gwarantuje bezpieczeństwo i ochronę danych użytkowników, co jest kluczowe w dynamicznie zmieniającym się środowisku przemysłowym.

Należy przypuszczać, że przewagę konkurencyjną zdobędzie ten, kto zrozumie, że można dostarczyć użytkownikowi zindywidualizowane doświadczenie z poszanowaniem jego praw. Firmy muszą oduczyć się pokusy gromadzenia informacji o kliencie i skupić się na tworzeniu wartości poprzez ochronę prywatności. Integracja nowych technologii z ludzkimi aspektami pracy oraz zapewnienie bezpieczeństwa i etyki danych będą kluczowe dla sukcesu przemysłu 5.0.

Bibliografia

- Alves, J., Gaspar, P.D., Lima, T.M. (2023). Is Industry 5.0 a Human-Centered Approach? A Systematic Review, *Processes*, 11(1), s. 193.
- Cavoukian, A. (2012). Privacy by Design [Leading Edge], *IEEE Technology and Society Magazine*, 31(4), s. 18–19.
- Costa Jr, P.T., McCrae, R.R. (1992). Four Ways Five Factors Are Basic, *Personality and Individual Differences*, 13, s. 653–665.
- Finck, M. (2021). The Limits of the GDPR in the Personalisation Context. W: *Data-Driven Personalisation in Markets, Politics and Law* (s. 95–107), U. Kohl, J. Eisler (Eds). Cambridge: Cambridge University Press.
- Kiepas, A. (2020). Człowiek w świecie procesów cyfryzacji – współczesne wyzwania i przyszłe skutki, *Filozofia i Nauka. Studia Filozoficzne i Interdyscyplinarne*, 8(1), s. 155–174.
- Kosinski, M., Stillwell, D., Graepel, T. (2013). Private Traits and Attributes Are Predictable from Digital Records of Human Behavior, *PNAS Proceedings of the National Academy of Sciences of the United States of America*, 110(15), s. 5802–5805. DOI: 10.1073/pnas.1218772110.
- Kovari, A. (2024). Industry 5.0: Generalized Definition, Key Applications, Opportunities and Threats, *Acta Polytechnica Hungarica*, 21(3), s. 267–284.
- Krzemińska, I. (2022). *Automatic Data-Based Personality Assessment As a Method of Electronic Services Auto-Personalisation (PhD Thesis)*, <https://bip.ue.poznan.pl/download/attachment/1325/rozprawa-doktorska-mgr-i-krzeminskiej.pdf> (dostęp: 14.10.2024).
- Krzemińska, I., Rzeźnik J. (2021). Personality-Based Lexical Differences in Services Adaptation Process, *Technium Romanian Journal of Applied Sciences and Technology*, 3, s. 61–73.
- Kuksa, I., Skinner, M., Fisher, T., Kent, T. (2022). *Delivering Personalised, Digital Experience. W: Understanding Personalisation: New Aspects of Design and Consumption* (s. 67–87). Amsterdam: Elsevier Science & Technology.

- Lin, Q., Jiang, S., Zhen, Z., Chen, T., Wei, C., Lin, H. (2024). Fed-PEMC: A Privacy-Enhanced Federated Deep Learning Algorithm for Consumer Electronics in Mobile Edge Computing, *IEEE Transactions on Consumer Electronics*, 70(1), s. 4073–4086. DOI: 10.1109/TCE.2024.3351648.
- Liu, Y., Kang, Y., Zou, T., Pu, Y., He, Y., Ye, X., Ouyang, Y., Zhang, Y.Q., Yang, Q. (2024). Vertical Federated Learning: Concepts, Advances, and Challenges, *IEEE Transactions on Knowledge and Data Engineering*, 36(7), s. 3615–3634. DOI: 10.1109/TKDE.2024.3352628.
- Nahavandi, S. (2019). Industry 5.0 – A Human-Centric Solution, *Sustainability*, 11(16), 4371.
- Peppers, K., Tuunanen, T., Rothenberger, M.A., Chatterjee, S. (2007). A Design Science Research Methodology for Information Systems Research, *Journal of Management Information Systems*, 24(3), s. 45–77.
- Rocha, L.D., Silva, G.R.S., Canedo, E.D. (2023). Privacy Compliance in Software Development: A Guide to Implementing the LGPD Principles. W: *Proceedings of the 38th ACM/SIGAPP Symposium on Applied Computing* (s. 1352–1361). DOI: 10.1145/3555776.3577615.
- Piccarozzi, M., Silvestri, L., Silvestri, C., Ruggieri, A. (2024). Roadmap to Industry 5.0: Enabling Technologies, Challenges, and Opportunities Towards a Holistic Definition in Management Studies, *Technological Forecasting and Social Change*, 205, 123467.
- Schrage, M. (2014). *The Innovator's Hypothesis: How Cheap Experiments Are Worth More Than Good Ideas*. Cambridge: The MIT Press.
- Trzcieliński, S. (2003). Lean Management a wirtualność przedsiębiorstwa, *Prace Naukowe Instytutu Organizacji i Zarządzania Politechniki Wrocławskiej. Konferencje* (23), 73, s. 291–306.
- Velasco, C., Reinoso-Carvalho, F., Escobar, F.B., Gustafsson, A., Petit, O. (2024). Paradoxes, Challenges, and Opportunities in the Context of Ethical Customer Experience Management, *Psychology and Marketing*. DOI: 10.1002/mar.22069.
- Venable, J., Pries-Heje, J., Baskerville, R. (2016). FEDS: a Framework for Evaluation in Design Science Research, *European Journal of Information Systems*, 25, s. 77–89.
- Zuboff, S. (2023). The Age of Surveillance Capitalism. W: *Social Theory Re-Wired* (s. 203–213), W. Longhofer, D. Winchester (Eds.). New York: Routledge.

