

REAKCJE UŻYTKOWNIKÓW PLATFORM CYFROWYCH NA REKOMENDACJE GENEROWANE PRZEZ SYSTEMY OPARTE NA SZTUCZNEJ INTELIGENCJI

Wojciech Trzebiński

Szkoła Główna Handlowa w Warszawie

Streszczenie

Systemy rekomendacyjne oparte na sztucznej inteligencji stanowią istotny element funkcjonowania platform cyfrowych. Dzięki tym systemom użytkownicy platform są w stanie lepiej wykorzystywać dostępne oferty produktowe. Jednak ludzie mogą postrzegać sztuczną inteligencję jako „maszynę”, kontrastując ją z cechami ludzkimi. W tej sytuacji niektóre komunikaty produktowe generowane przez sztuczną inteligencję, które mogą być postrzegane jako wkraczające w specyficznie „ludzkie” domeny (np. język korzyści czy odwołania do motywów hedonistycznych), mogą prowadzić do postrzeganej niespójności, a w konsekwencji – do negatywnych reakcji użytkowników. Te negatywne efekty mogą być łagodzone przez postrzegany antropomorfizm sztucznej inteligencji.

Słowa kluczowe: rekomendacje produktowe, sztuczna inteligencja, język korzyści, motywy hedonistyczne, antropomorfizm

Wprowadzenie

Inteligentne systemy rekomendacyjne zwiększają wartość platform cyfrowych dla swoich użytkowników, ale korzystanie z rekomendacji udzielanych przez algorytm może napotykać na opór, gdy rekomendacje te wkraczają w sferę „ludzką”, a mianowicie – domenę życia osobistego użytkownika. Wtedy system może być uznany za mało odpowiedni do udzielania takich rekomendacji, ponieważ jego użytkownicy mogą nie być w stanie docenić zdolności systemu do zrozumienia tej „ludzkiej” perspektywy.

Celem tego rozdziału jest wskazanie – na podstawie wyników najnowszych badań – kiedy i dlaczego użytkownicy inteligentnych systemów rekomendacyjnych mogą negatywnie reagować na ich rekomendacje, a także – jakie są możliwości złagodzenia tych efektów.

1. Systemy rekomendacyjne na platformach cyfrowych

Systemy rekomendacyjne to aplikacje, które przedstawiają swoim użytkownikom propozycje przedmiotów, które według określonych kryteriów są odpowiednie dla tych użytkowników [Del Carmen Rodríguez-Hernández, Illari, 2021]. Systemy rekomendacyjne tworzone są dla różnych rodzajów rekomendowanych przedmiotów, od typowych produktów komercyjnych (np. systemy wbudowane w platformy *e-commerce* jak Amazon), poprzez produkty cyfrowe udostępniane w ramach subskrypcji (np. propozycje filmów w serwisie Netflix czy utworów muzycznych w serwisie Spotify), po treści cyfrowe tworzone przez innych użytkowników w mediach społecznościowych (np. posty w serwisie Facebook). Różnorodne są też kryteria, na podstawie których algorytmy systemów rekomendacyjnych dobierają propozycje przedmiotów dla swoich użytkowników [Chinchanachokchai, Thontirawong, Chinchanachokchai, 2021; Del Carmen Rodríguez-Hernández, Illari, 2021; Fayyaz *et al.*, 2020; Labecki, Klaus, Zaichkowsky, 2018; Lee, Hosanagar, 2021; Schreiner, Rese, Baier, 2019]. Systemy te mogą się opierać na cechach danego użytkownika oraz obserwacji jego zachowania w Internecie (np. jego wcześniejsze wybory produktów czy przeglądanych treści), a także obserwacji zachowania użytkowników ocenianych przez system jako podobnych do danego użytkownika. Systemy rekomendacyjne mogą też wnioskować o preferencjach użytkownika na podstawie jego bezpośrednich deklaracji, wyrażonych poprzez ustawienie filtrowania przedmiotów lub przekazanych przez niego informacji o preferencjach czy odpowiadających mu produktach. Wreszcie, systemy rekomendacyjne mogą wykorzystywać dane sytuacyjne (np. lokalizacja użytkownika, pora dnia czy dzień tygodnia).

Systemy rekomendacyjne wpływają na swoich użytkowników poprzez informowanie ich o nieznanym im wcześniej przedmiotach oraz zwracanie uwagi na przedmioty już wcześniej im znane [Lee, Hosanagar, 2021]. W ten sposób systemy rekomendacyjne mogą ułatwiać użytkownikom radzenie sobie z nadmiarem informacji produktowych w Internecie [Fayyaz *et al.*, 2020]. Ponadto systemy rekomendacyjne mogą pomóc podejmować konsumentom bardziej racjonalne decyzje zakupowe, oparte w większym stopniu na jakości produktu niż na takich wskazówkach jak marka [Knijnenburg *et al.*, 2012; Labecki, Klaus, Zaichkowsky, 2018; Zhang, Curley, 2018], przejmując za

nich ciężar rozumowania na podstawie złożonej informacji o atrybutach przedmiotów [Fayyaz *et al.*, 2020]. W platformach cyfrowych systemy rekomendacyjne mogą wspierać efekty sieciowe, a mianowicie użytkownicy tych systemów mogą korzystać z doświadczenia produktowego innych użytkowników [Belleflamme, Peitz, 2021]. W szczególności systemy rekomendacyjne mogą sugerować użytkownikom o skąpej wiedzy produktowej produkty wybierane przez użytkowników posiadających większą wiedzę produktową.

2. Postrzeżenie inteligencji systemów rekomendacyjnych

Przetwarzanie opisanych wyżej złożonych danych o przedmiotach i użytkownikach oraz wnioskowanie na ich podstawie o optymalnych dla danego użytkownika przedmiotach jest w systemach rekomendacyjnych zazwyczaj oparte o zaawansowane metody sztucznej inteligencji, jak sieci neuronowe, algorytmy genetyczne czy algorytmy rozmyte [Zhang, Lu, Jin, 2021]. W konsekwencji użytkownik systemów rekomendacyjnych może dostrzegać inteligencję systemu rekomendacyjnego, choć należy rozróżnić obiektywnie określoną inteligencję systemu (mierzoną np. trafnością przewidywań) od subiektywnej oceny inteligencji dokonywanej przez użytkowników, którzy mogą w większym lub mniejszym stopniu doceniać stopień, w jakim system radzi sobie z rozwiązywaniem problemów [Li, 2016].

Użytkownicy postrzegają inteligencję wytworzonych przez człowieka obiektów (tu: systemów rekomendacyjnych) w oparciu o różne wymiary, takie jak zdolność do uczenia się, autonomia, reaktywność czy zdolność do współpracy z innymi obiektami, a także wymiary antropomorficzne, czyli bezpośrednio związane z podobieństwem obiektu do człowieka, takie jak osobowość czy ludzki sposób interakcji [Rijsdijk, Hultink, Diamantopoulos, 2007]. Zdolność do uczenia się to stopień, w jakim system jest w stanie gromadzić i wykorzystywać informacje przydatne do rozwiązywania problemów (tu: generowanie rekomendacji przedmiotów dla użytkownika), w tym informacje o samym użytkowniku. Autonomia to stopień, w jakim system generuje rekomendacje samodzielnie i z własnej inicjatywy. Reaktywność to elastyczność, z jaką system dostosowuje się do zmieniających się warunków (jak asortyment produktów, preferencje użytkownika czy jego lokalizacja). Wymiar określany jako osobowość systemu to stopień, w jakim posiada on, w postrzeganiu użytkownika, określone cechy charakteru oraz stany emocjonalne występujące u ludzi. Wreszcie, ludzki sposób interakcji systemu to stopień, w jakim komunikuje się on z użytkownikiem podobnie jak inni ludzie. Wymiary antropomorficzne są związane z postrzeganą inteligencją systemu, ponieważ inteligencję obiektów można określić jako zdolność rozwiązywania problemów

na sposób ludzki [Duffy, 2003]. Zatem wykazując inteligencję, system może wydawać się bardziej ludzki i na odwrót – wydając się bardziej ludzki, system może być postrzegany jako inteligentniejszy. Użytkownicy systemów rekomendacyjnych, dostrzegając ich inteligencję, stosują w reakcji na te systemy określone schematy myślenia o sztucznej inteligencji. Mogą one być pozytywne, jak „heurystyka maszyny” [Sundar, Kim, 2019], według której sztuczna inteligencja jest bardziej obiektywna niż człowiek, a więc wolna jest od uprzedzeń i skoncentrowana na meritum problemu. W konsekwencji system rekomendacyjny może być przez użytkownika uznany za źródło racjonalnych sugestii produktowych. Sztuczna inteligencja może być też postrzegana jako źródło zagrożenia dla ludzi [Perez Garcia, Saffon Lopez, 2018], np. system rekomendacyjny może być odbierany jako autonomiczny algorytm realizujący własne cele, być może poprzez wpływanie na zachowania swoich użytkowników (np. zainteresowanie określoną kategorią produktową). Te dwa przeciwstawne schematy łączy traktowanie sztucznej inteligencji w kontraście do człowieka, zatem system rekomendacyjny może być postrzegany jako „nieludzki” w tym sensie, że jest pozbawiony emocji i możliwości zrozumienia człowieka [Lou, Kang, Tse, 2022]. Innymi słowy, użytkownicy mogą uznawać, że ludzie – jako gatunek – mają wyłączność na posiadane tego rodzaju zdolności [Lopez, Garza, 2023]. Jednak udokumentowana jest też przeciwstawna tendencja – do traktowania komputerów jako „aktorów społecznych”, czyli innych ludzi, z którymi można mieć ludzkie interakcje, np. oparte na wdzięczności [Nass, Moon, 2000]. Ponadto ludzie mają tendencję do antropomorfizowania przedmiotów [Epley, Waytz, Cacioppo, 2007], czyli postrzegania ich jako podobnych do ludzi, co dotyczy również systemów i aplikacji komputerowych [Müller *et al.*, 2018; Rzepka, Berger, 2018; Sacino *et al.*, 2022]. Zatem użytkownicy systemów rekomendacyjnych, postrzegając ich inteligencję, mogą je traktować różnie w zależności od aktywowanego schematu myślenia. W szczególności użytkownicy mogą reagować na rekomendacje takich systemów, zakładając, że systemy te są w mniejszym lub większym stopniu „nieludzkie” bądź „ludzkie”.

3. Reakcje użytkowników na rekomendacje systemów opartych na sztucznej inteligencji

Jeśli przyjąć, że ludzie zazwyczaj postrzegają sztuczną inteligencję w kontraście do człowieka [Kim, Duhachek, 2020; Longoni, Cian, 2022; Lou, Kang, Tse, 2022] (np. jako „bezduszną maszynę”), można by oczekiwać, że niektóre rodzaje rekomendacji systemów opartych na sztucznej inteligencji będą przyjmowane przez użytkowników mniej pozytywnie, niż gdyby pochodziły od człowieka. Chodzi tu o rekomendacje

postrzegane przez użytkownika jako silnie odwołujące się do perspektywy „ludzkiej”. W szczególności mogą to być rekomendacje produktowe oparte na języku korzyści oraz motywach hedonistycznych. Mniej pozytywne postrzeganie takich rekomendacji może stanowić barierę w rozwoju korzystania z systemów rekomendacyjnych. Jednak określone czynniki, jak postrzeganie systemu jako bardziej ludzki (tj. antropomorfizacja systemu), mogą zwiększyć pozytywne reakcje użytkowników na takie rekomendacje.

3.1. Rekomendacje oparte na języku korzyści vs. cech

Według teorii środków do celu (*Means-End Chain Theory* [Gutman, 1982; Heinze, Thomann, Fischer, 2017; Lin, Fu, Chen, 2019; Lin, Fu, 2018]) konsumenci organizują swoją wiedzę produktową według poziomu abstrakcyjności informacji o produkcie. Informacje najbardziej konkretne dotyczą namacalnych cech produktu i są one w umyśle konsumentów agregowane do bardziej abstrakcyjnych cech w oparciu o to, do czego te konkretne cechy służą (np. szczelność i wytrzymałość obudowy smartfonu, a więc cechy bardziej konkretne, mogą służyć trwałości telefonu, a więc cesze ogólniejszej). Z kolei cechy ogólne agregowane są do korzyści produktu (np. trwałość i niezawodność telefonu może dać jego użytkownikowi poczucie bezpieczeństwa), a te do celów realizowanych przez ten produkt (np. poczucie bezpieczeństwa i stały dostęp do Internetu mogą sprzyjać realizacji celu użytkownika w postaci bycia osobą niezależną). Posuwając się wzdłuż tego łańcucha, informacje ogólniejsze są mocniej związane z perspektywą osobistą konsumenta, a więc jego celami, wartościami i potrzebami. Bardziej abstrakcyjna informacja o produkcie (np. oparta na korzyści ze smartfonu jaką jest poczucie bezpieczeństwa) wymaga więc interpretacji informacji konkretnej (np. opartej na cechach smartfonu, jak trwałość i niezawodność) w oparciu o „ludzką” perspektywę (np. wiedzę o tym, że te cechy smartfonu mogą w określonych sytuacjach życiowych, np. podczas podróży daleko od domu i bliskich, dać użytkownikowi poczucie bezpieczeństwa). Zgodnie ze schematem „nieludzkiej” sztucznej inteligencji można by więc oczekiwać mniej pozytywnej reakcji konsumentów na rekomendacje systemu oparte na korzyściach (vs. cechach) produktu. Potwierdziły to badania [Kim, Duhachek, 2020] – np. porównano intencje zakupu kremu przeciwsłonecznego rekomendowanego za pomocą korzyści (np. zdrowa skóra) oraz cech (np. szybkie wchłanianie w skórę) w sytuacji, gdy rekomendującym był człowiek albo system. W przypadku systemu intencja zakupu była niższa, gdy rekomendacja opierała się na korzyściach – nie zauważono natomiast tej różnicy, gdy rekomendującym był człowiek. Kim i Duhachek [2020] stwierdzili, że ta negatywna reakcja na rekomendacje systemu oparte na korzyściach jest łagodzona przez zakomunikowanie użytkownikom, że system (mający postać robota) ma zdolność uczenia się oraz nadanie systemowi cech

antropomorficznych (system nazwano ludzkim imieniem „Alex” oraz zasugerowano uczestnikom badania, że system „jest świadomy swojego istnienia”). W najnowszych badaniach [Trzebiński, Marciniak, Kulczycka, 2023] uczestnicy badania korzystający z systemu rekomendującego smartfony w wersji zantropomorfizowanej (poprzez umieszczenie schematycznej ikony głowy, posługiwanie się przez system pierwszą osobą oraz umieszczenie jego komunikatów w dymkach przypominających ludzkie wypowiedzi) wykazali wyższy poziom postrzeganej zdolności systemu do uczenia się o użytkownika oraz postrzeganej odpowiedniości tego systemu do udzielania rekomendacji opartych na korzyściach smartfonu (np. „zapewnia dostęp do Internetu”) niż uczestnicy korzystający z systemu bez powyższych wskazówek antropomorficznych. Ponadto postrzegana zdolność do uczenia się mediowała pozytywną zależność między antropomorfizacją systemu a postrzeganą odpowiednością rekomendacji opartych na korzyściach. Co ważne, efekt antropomorfizacji systemu na postrzeganą odpowiedniość systemu do udzielania rekomendacji opartych na cechach (np. „niezawodność”) był istotnie mniej pozytywny. Można więc przypuszczać, że antropomorfizacja systemu powoduje, że jego użytkownicy uznają go za bardziej odpowiedni do posługiwania się „ludzka” perspektywą produktu, a więc jego korzyściami.

3.2. Rekomendacje oparte na motywach hedonistycznych vs. użytecznych

Wyróżnia się dwa podstawowe motywy nabywania produktów: użyteczny i hedonistyczny [Scarpi, 2020]. Pierwszy z nich polega na tym, że konsumenci nabywają produkty, ponieważ są im przydatne do realizacji określonego zadania. Na przykład możemy kupować kawę, ponieważ chcemy efektywniej pracować. Możemy również kupować kawę, ponieważ jej picie sprawia nam przyjemność (motyw hedonistyczny). W tym przypadku konsument nabywa produkt dla przyjemności z samego produktu, bez odniesienia do jakiegoś zadania, do którego realizacji ten produkt mógłby się przydać. Ten sam produkt, jak kawa, może więc być nabywany zarówno w oparciu o motyw użyteczny, jak i hedonistyczny. Znaczenie każdego z tych motywów może wynikać z predyspozycji danego konsumenta oraz z sytuacji zakupowej. W związku z tym użytkownicy platform cyfrowych mogą reagować na komunikaty produktowe inteligentnych systemów rekomendacyjnych w oparciu o hedonistyczny lub użyteczny motyw zakupowy. Podobnie jak w przypadku rozróżnienia na komunikaty oparte na korzyściach vs. cechach produktu, komunikaty oparte na motywie hedonistycznym vs. użytecznym mogą być przez konsumentów postrzegane jako w różnym stopniu związane z „ludzka” perspektywą. Mianowicie przyjemność może być traktowana jako stan typowo ludzki. O ile bowiem wykonywanie zadań może być kojarzone z działaniem inteligentnej maszyny, o tyle przeżywanie przyjemności to raczej domena człowieka –

dla maszyny niedostępna [Longoni, Cian, 2022]. Zatem rekomendowanie produktu w oparciu o motyw hedonistyczny może być przez użytkowników systemu rekomendacyjnego postrzegane jako niespójne ze schematem pozbawionej emocji „niehumanoidalnej” maszyny [Lou, Kang, Tse, 2022]. Z drugiej strony rekomendowanie w oparciu o motyw użyteczny może być traktowane jako spójne ze „heurystyką maszyny” [Sundar, Kim, 2019], która zakłada racjonalność i obiektywizm maszyny zorientowanej na sprawne wykonywanie zadań.

Wyniki badawcze potwierdzają odmienną reakcję użytkowników inteligentnych systemów rekomendacyjnych na komunikaty produktowe oparte na motywach hedonistycznym i użytecznym. W jednym z eksperymentów przeprowadzonych przez Longoni i Cian [2022] uczestnicy wybierali pomiędzy dwoma próbkami maski do włosów. Uczestników podzielono na dwie grupy. W pierwszej grupie (motyw hedonistyczny) uczestników poproszono, aby wyobrazili sobie, że kupują ten produkt ze względu na przyjemność, zapach i pozytywny nastrój, jaki może on dać. W drugiej grupie (motyw użyteczny) uczestnicy mieli zwracać uwagę na praktyczność i skuteczność użycia maski. Większość osób z grupy hedonistycznej wybrała próbkę oznaczoną jako rekomendacja człowieka, natomiast większość osób z grupy użytecznej wybrała próbkę oznaczoną jako rekomendacja algorytmu. Podobny wynik otrzymano, gdy zamiast próbki produktu uczestnicy wybierali między kopertami zawierającymi oferty nieruchomości rekomendowane przez człowieka albo algorytm, w zależności od tego, czy zwracano uwagę na znaczenie przyjemności z nieruchomości czy też jej użyteczności.

Podobnie jak w przypadku języka korzyści w kontraście z językiem cech, dla motywu hedonistycznego w kontraście z użytecznym stwierdzono, że mniej pozytywna reakcja na takie rekomendacje inteligentnego systemu może być złagodzona, jeśli system będzie postrzegany jako bardziej antropomorficzny. W eksperymencie Wiena i Peluso [2021] system rekomendujący smartfony był nazwany „CX1” (niski antropomorfizm) lub imieniem ludzkim (wysoki antropomorfizm), a do tego dodano, odpowiednio, ikonę robota lub człowieka. Uczestników proszono, by wyobrazili sobie, że kupują smartfon dla przyjemności (motyw hedonistyczny) lub do pracy (motyw użyteczny). W obu przypadkach system rekomendował ten sam smartfon, a uczestnicy eksperymentu określali, na ile chcą go kupić. Okazało się, że w przypadku motywu hedonistycznego intencja zakupu była większa, gdy system przedstawiono jako bardziej ludzki. Najnowsze badania [Trzebiński, Marciniak, Kulczycka, 2023] wskazują, że pozytywny efekt postrzeganego antropomorfizmu systemu rekomendacyjnego na reakcję na jego rekomendacje oparte na motywie hedonistycznym (np. „ten smartfon sprawi ci przyjemność z oglądania obrazu w najlepszej jakości”) jest mediowany przez postrzeganie zdolności systemu do uczenia się na temat użytkownika. Dokładniej, gdy system jest postrzegany jako bardziej ludzki, jego użytkownicy uznają go

za bardziej zdolny do uczenia się, co z kolei jest pozytywnie związane z postrzeganą odpowiednością systemu do formułowania takich rekomendacji. Co więcej, uczestnicy badania określali na ile rekomendacje systemu odwołują się do „zabawy i rozrywki” (motyw hedonistyczny), a na ile do „zwykłych czynności, w których smartfon może pomóc” (motyw użyteczny). Im bardziej rekomendacje postrzegane były jako oparte na motywie hedonistycznym, tym bardziej pozytywny był związek postrzeganej zdolności systemu do uczenia się z postrzeganą odpowiednością rekomendacji. Może to sugerować, że pozytywna reakcja użytkownika na rekomendowanie produktów w oparciu o przyjemność wymaga, aby użytkownik uznawał system za zdolny do zrozumienia „ludzkiej” perspektywy.

Podsumowanie

Przedstawione wyżej koncepcje i wyniki badawcze wskazują na ograniczenia w zastosowaniu inteligentnych systemów rekomendacyjnych w platformach cyfrowych. Rekomendowanie produktów w oparciu o język korzyści czy motyw hedonistyczny wydaje się być postrzegane przez użytkowników jako rola przynależna raczej człowiekowi, a nie algorytmowi. Ten ostatni może być uznawany za niekompetentny w rozumieniu „ludzkiej” perspektywy osobistego życia użytkownika, w tym korzystania z produktów i czerpania z nich przyjemności. Aby złagodzić te opory użytkowników, można uczynić system bardziej ludzkim, np. nadając mu ludzkie imię, ikonę czy używając pierwszej osoby w komunikatach systemu.

Rozwój systemów inteligentnych i ich znaczenia w platformach cyfrowych czyni kwestie reakcji użytkowników na komunikaty tych systemów ważnym kierunkiem badawczym. Warto badać reakcje na coraz to nowsze formy działania systemów inteligentnych ingerujące w „ludzką” perspektywę, jak porady osobiste [Hildebrand, Bergner, 2021; Zhang *et al.*, 2020], ocenianie użytkownika (np. tekstu przez niego opracowanego [Lopez, Garza, 2023]), sądy etyczne [Cervantes *et al.*, 2020] czy synteza treści w postaci esejów (np. Chat GPT). W szczególności sformułować można następujące pytania: Czy reakcja użytkowników na powyższe formy aktywności jest mniej pozytywna, jeśli są one dokonywane przez system inteligentny vs. człowieka? Jeśli tak, czy antropomorfizacja systemu może poprawić te reakcje? Jakie inne zabiegi – np. wyjaśnienie użytkownikowi zasad działania algorytmu – mogą pomóc? Wreszcie: Czy jakość relacji użytkownika z marką związaną z algorytmem lub platformą cyfrową może wpłynąć pozytywnie na te reakcje?

Bibliografia

- Belleflamme, P., Peitz, M. (2021). *The Economics of Platforms*. Cambridge: Cambridge University Press.
- Cervantes, J.A., López, S., Rodríguez, L.F., Cervantes, S., Cervantes, F., Ramos, F. (2020). Artificial Moral Agents: A Survey of the Current Status, *Science and Engineering Ethics*, 26(2), s. 501–532.
- Chinchanachokchai, S., Thontirawong, P., Chinchanachokchai, P. (2021). A Tale of Two Recommender Systems: The Moderating Role of Consumer Expertise on Artificial Intelligence Based Product Recommendations, *Journal of Retailing and Consumer Services*, 61. DOI: 10.1016/j.jretconser.2021.102528.
- Del Carmen Rodríguez-Hernández, M., Ilarri, S. (2021). AI-Based Mobile Context-Aware Recommender Systems from an Information Management Perspective: Progress and Directions, *Knowledge-Based Systems*, 215. DOI: 10.1016/j.knosys.2021.106740.
- Duffy, B.R. (2003). Anthropomorphism and the Social Robot, *Robotics and Autonomous Systems*, 42 (3–4), s. 177–190.
- Epley, N., Waytz, A., Cacioppo, J.T. (2007). On Seeing Human: A Three-Factor Theory of Anthropomorphism, *Psychological Review*, 114(4), s. 864–886.
- Fayyaz, Z., Ebrahimian, M., Nawara, D., Ibrahim, A., Kashef, R. (2020). Recommendation Systems: Algorithms, Challenges, Metrics, and Business Opportunities, *Applied Sciences*, 10(21). DOI: 10.3390/app10217748.
- Gutman, J. (1982). A Means-End Chain Model Based on Consumer Categorization Processes, *Journal of Marketing*, 46(2), s. 60–72.
- Heinze, J., Thomann, M., Fischer, P. (2017). Ladders to M-Commerce Resistance: A Qualitative Means-End Approach, *Computers in Human Behavior*, 73, s. 362–374.
- Hildebrand, C., Bergner, A. (2021). Conversational Robo Advisors as Surrogates of Trust: Onboarding Experience, Firm Perception, and Consumer Financial Decision Making, *Journal of the Academy of Marketing Science*, 49, s. 659–676.
- Kim, T.W., Duhachek, A. (2020). Artificial Intelligence and Persuasion: A Construal-Level Account, *Psychological Science*, 31(4), s. 363–380.
- Knijnenburg, B.P., Willemsen, M.C., Gantner, Z., Soncu, H., Newell, C. (2012). Explaining the User Experience of Recommender Systems, *User Modeling and User-Adapted Interaction*, 22(4–5), s. 441–504.
- Labecki, A., Klaus, P., Zaichkowsky, J.L. (2018). How Bots Have Taken over Brand Choice Decisions. W: *Proceedings of the Future Technologies Conference 2018*, 2 (s. 976–989), K. Arai, R. Bhatia, S. Kapoor (Eds.). Springer International Publishing.
- Lee, D., Hosanagar, K. (2021). How do Product Attributes and Reviews Moderate the Impact of Recommender Systems through Purchase Stages?, *Management Science*, 67(1), s. 524–546.
- Li, C. (2016). When Does Web-Based Personalization Really Work? The Distinction between Actual Personalization and Perceived Personalization, *Computers in Human Behavior*, 54, s. 25–33.
- Lin, C.F., Fu, C.S. (2018). Evaluating Online Advertising Effect: An Approach Integrating Means-End Conceptualization and Similarity Analysis, *Electronic Commerce Research and Applications*, 32, s. 1–12.

- Lin, C.F., Fu, C.S., Chen, Y.T. (2019). Exploring Customer Perceptions Toward Different Service Volumes: An Integration of Means-End Chain and Balance Theories, *Food Quality and Preference*, 73, s. 86–96.
- Longoni, C., Cian, L. (2022). Artificial Intelligence in Utilitarian vs. Hedonic Contexts: The „Word-of-Machine” Effect, *Journal of Marketing*, 86(1), s. 91–108.
- Lopez, A., Garza, R. (2023). Consumer Bias Against Evaluations Received by Artificial Intelligence: The Mediation Effect of Lack of Transparency Anxiety, *Journal of Research in Interactive Marketing*, 17(6), s. 831–847.
- Lou, C., Kang, H., Tse, C.H. (2022). Bots vs. Humans: How Schema Congruity, Contingency-Based Interactivity, and Sympathy Influence Consumer Perceptions and Patronage Intentions, *International Journal of Advertising*, 41(4), s. 655–684.
- Müller, B.C., Chen, S., Nijssen, S.R., Kühn, S. (2018). How (Not) to Increase Older Adults’ Tendency to Anthropomorphise in Serious Games, *PLOS ONE*, 13(7). DOI: 10.1371/journal.pone.0199948.
- Nass, C., Moon, Y. (2000). Machines and Mindlessness: Social Responses to Computers, *Journal of Social Issues*, 56(1), s. 81–103.
- Perez Garcia, M., Saffon Lopez, S. (2018). Building Trust between Users and Telecommunications Data Driven Virtual Assistants. W: *Artificial Intelligence Applications and Innovations: 14th IFIP WG 12.5 International Conference, AIAI 2018, Rhodes, Greece, May 25–27, 2018, Proceedings 14* (s. 628–637), L. Iliadis, I. Maglogiannis, V. Plagianakos (Eds.). Springer International Publishing.
- Rijsdijk, S.A., Hultink, E.J., Diamantopoulos, A. (2007). Product Intelligence: Its Conceptualization, Measurement and Impact on Consumer Satisfaction, *Journal of the Academy of Marketing Science*, 35, s. 340–356.
- Rzepka, C., Berger, B. (2018). User Interaction with AI-Enabled Systems: A Systematic Review of IS Research. W: *Thirty Ninth International Conference on Information Systems, San Francisco 2018*, 39.
- Sacino, A., Cocchella, F., De Vita, G., Bracco, F., Rea, F., Sciutti, A., Andrighetto, L. (2022). Human- or Object-Like? Cognitive Anthropomorphism of Humanoid Robots, *PLOS ONE*, 17(7). DOI: 10.1371/journal.pone.0270787.
- Scarpi, D. (2020). *Hedonism, Utilitarianism, and Consumer Behavior: Exploring the Consequences of Customer Orientation*. Cham: Springer Nature.
- Schreiner, T., Rese, A., Baier, D. (2019). Multichannel Personalization: Identifying Consumer Preferences for Product Recommendations in Advertisements Across Different Media Channels, *Journal of Retailing and Consumer Services*, 48, s. 87–99.
- Sundar, S.S., Kim, J. (2019). Machine Heuristic: When We Trust Computers More than Humans with Our Personal Information. W: *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems. 4–9 May 2019, Glasgow, UK* (s. 1–9), S. Brewster, G. Fitzpatrick (Eds.). New York, NY: ACM.
- Trzebiński, W., Marciniak, B., Kulczycka, E. (2023). Online Recommenders’ Anthropomorphism Improves User Response to Hedonic and Benefit-Based Product Appeals Through the Recommenders’ Perceived Ability to Learn, *PLOS ONE*, 18(6). DOI: 10.1371/journal.pone.0287663.
- Wien, A.H., Peluso, A.M. (2021). Influence of Human versus AI Recommenders: The Roles of Product Type and Cognitive Processes, *Journal of Business Research*, 137(4), s. 13–27.

Zhang, J., Curley, S.P. (2018). Exploring Explanation Effects on Consumers' Trust in Online Recommender Agents, *International Journal of Human – Computer Interaction*, 34(5), s. 421–432.

Zhang, J., Oh, Y.J., Lange, P., Yu, Z., Fukuoka, Y. (2020). Artificial Intelligence Chatbot Behavior Change Model for Designing Artificial Intelligence Chatbots to Promote Physical Activity and a Healthy Diet, *Journal of Medical Internet Research*, 22(9). DOI: 10.2196/22845.

Zhang, Q., Lu, J., Jin, Y. (2021). Artificial Intelligence in Recommender Systems, *Complex & Intelligent Systems*, 7, s. 439–457.