




**Tomasz Kliś**  <https://orcid.org/0009-0009-6944-3217>

Niezależny badacz

# MARKETING OPARTY NA DANYCH. SKUTECZNOŚĆ I PERCEPCJA ALGORYTMÓW PREDYKCYJNYCH WŚRÓD KONSUMENTÓW

Abstract

## DATA-DRIVEN MARKETING: THE EFFECTIVENESS AND PERCEPTION OF PREDICTIVE ALGORITHMS AMONG CONSUMERS

The article focuses on the role of predictive algorithms in data-driven marketing and their ability to anticipate consumer needs. The main objective of the study was to examine the effectiveness of personalized marketing content and assess the impact of predictive technologies on purchasing decisions and customer loyalty. The research addresses a knowledge gap concerning the synergistic use of various predictive techniques within integrated marketing strategies. A mixed-method approach was applied, combining a literature review with empirical research based on an online survey involving 200 respondents. Statistical methods, including correlation and regression analysis, were employed. The results indicated that content personalization significantly influences purchasing behavior and consumer satisfaction. A positive correlation was also observed between online shopping frequency and the perceived accuracy of product recommendations. The article additionally considers the ethical and regulatory context of using AI in marketing, emphasizing the need for further research in this area. This study presents an interdisciplinary perspective, integrating technological, psychological, and legal aspects in the analysis of modern marketing strategies.

**Keywords:** predictive marketing, artificial intelligence algorithms, personalization, consumer behavior, data analysis

**JEL:** M31, C55, D83

## Wprowadzenie

W dobie cyfryzacji i rosnącej liczby danych marketing oparty na analizie informacji staje się kluczowym narzędziem umożliwiającym przedsiębiorstwom skuteczniejsze docieranie do konsumentów. Algorytmy sztucznej inteligencji (SI) i uczenia maszynowego (ML) coraz częściej pozwalają firmom przewidywać potrzeby klientów, personalizować oferty i optymalizować strategie komunikacji (Sivarajah i in., 2017). Dzięki wykorzystaniu zaawansowanych modeli analizy danych możliwe jest nie tylko lepsze dopasowanie treści reklamowych, ale także prognozowanie przyszłych zachowań konsumentów.

Główne tezy niniejszego artykułu koncentrują się na roli algorytmów w identyfikowaniu wzorców zakupowych oraz ich wpływie na decyzje konsumentów. Przedstawiona w nim zostanie zatem analiza metod wykorzystywanych w predykcyjnym modelowaniu zachowań klientów, a także omówiona efektywność tych narzędzi w kontekście marketingowym. Hipotezy badawcze brzmią:

1. Algorytmy oparte na danych skutecznie przewidują potrzeby konsumentów poprzez analizę ich wcześniejszych interakcji z marką.
2. Personalizacja treści marketingowych zwiększa zaangażowanie konsumentów oraz ich skłonność do dokonania zakupu.
3. Istnieją różnice w skuteczności algorytmów predykcyjnych w zależności od branży oraz typu oferowanego produktu lub usługi.

Pomimo licznych badań nad wykorzystaniem sztucznej inteligencji w marketingu wciąż istnieją luki badawcze, które wymagają uzupełnienia. Dotychczasowe analizy często skupiają się na skuteczności pojedynczych metod predykcyjnych, pomijając ich synergiczne działanie w ramach kompleksowych strategii marketingowych. Niniejszy artykuł wypełnia tę lukę, przedstawiając interdyscyplinarne podejście do wykorzystania algorytmów w przewidywaniu potrzeb konsumentów. Dodatkowo uwzględniona zostanie kwestia etycznych aspektów stosowania SI w marketingu, co jest istotnym, lecz wciąż niedostatecznie eksplorowanym obszarem badań.

Jak wskazuje Rószkiewicz (2016), algorytmy predykcyjne odgrywają kluczową rolę w nowoczesnym zarządzaniu relacjami z klientami (CRM). Dzięki wykorzystaniu metod analitycznych, takich jak analiza regresyjna, drzewa decyzyjne czy modele oparte na sztucznych sieciach neuronowych, przedsiębiorstwa mogą skuteczniej przewidywać potrzeby konsumentów i dostosowywać swoje strategie marketingowe. Autorzy literatury przedmiotu twierdzą, że połączenie różnych technik predykcyjnych może prowadzić do bardziej precyzyjnych prognoz, co potwierdza zasadność stosowania zaawansowanej analityki w marketingu opartym na danych.

W kolejnych częściach artykułu zostanie zaprezentowany przegląd literatury dotyczącej omawianego zagadnienia, analiza wybranych metod algorytmicznych oraz ich praktyczne zastosowanie w kampaniach marketingowych. Ostatecznym celem pracy jest określenie stopnia, w jakim marketing oparty na danych może skutecznie

przewidywać potrzeby konsumentów, oraz sposobu, w jaki przedsiębiorstwa mogą wykorzystać te technologie do budowania długoterminowych relacji z klientami.

Na podstawie przeglądu literatury, który przedstawiono w kolejnym podrozdziale, sformułowano następujące cele badawcze pracy:

1. Analiza skuteczności algorytmów predykcyjnych w przewidywaniu potrzeb konsumentów.
2. Ocena wpływu personalizacji marketingowej na satysfakcję klientów.
3. Zbadanie roli interaktywnych treści w budowaniu zaangażowania konsumentów.

Ponadto postawiono następujące pytania badawcze:

1. W jakim stopniu algorytmy predykcyjne poprawiają trafność rekomendacji produktowych?
2. Czy personalizacja treści marketingowych prowadzi do zwiększenia lojalności konsumentów?
3. Jakie techniki interaktywne najlepiej wspierają skuteczność algorytmów marketingowych?

Powyższe pytania i cele badawcze będą analizowane w dalszej części pracy, na podstawie badań empirycznych przeprowadzonych na grupie respondentów.

## Tło teoretyczne

Badania nad marketingiem opartym na danych koncentrują się na kilku kluczowych aspektach, takich jak analiza predykcyjna, satysfakcja klientów, zachowania konsumentów w erze cyfrowej oraz rola interaktywnych treści w angażowaniu odbiorców. W niniejszym rozdziale dokonano przeglądu literatury bazującego na wybranych pracach naukowych i branżowych.

### Analiza predykcyjna w zarządzaniu relacjami z klientami

Artykuł Rószkiewicza (2016) podkreśla znaczenie analityki predykcyjnej w identyfikowaniu wzorców zakupowych konsumentów. Wskazuje on, że algorytmy uczenia maszynowego mogą znacząco poprawić skuteczność strategii marketingowych poprzez automatyczne segmentowanie klientów i przewidywanie ich przyszłych decyzji zakupowych. Zastosowanie tych metod pozwala firmom na lepsze dopasowanie ofert do potrzeb klientów, co skutkuje zwiększoną lojalnością i wyższą konwersją sprzedaży.

## Modele satysfakcji klienta

Według Biesoka i Wyród-Wróbel (2016) satysfakcja klienta jest kluczowym czynnikiem wpływającym na długoterminowe relacje z marką. Ich publikacja *Modele satysfakcji klienta* przedstawia różne teoretyczne podejścia do oceny poziomu satysfakcji oraz jej wpływu na lojalność konsumentów. W perspektywie marketingu predykcyjnego modele te mogą być wykorzystywane do oceny skuteczności personalizacji treści marketingowych oraz przewidywania, które czynniki mają największy wpływ na doświadczenie klienta.

## Zachowania konsumenta w erze cyfrowej

Tarczydło (2016) w pracy *Konsument digitalny i jego zachowania. Przegląd badań* analizuje zmiany w zachowaniach konsumentów wynikające z cyfryzacji i rozwoju technologii. Podkreśla, że współczesny konsument jest bardziej świadomy, wymagający oraz oczekuje spersonalizowanej komunikacji. W świetle tych badań marketing oparty na danych powinien koncentrować się na dostarczaniu wartościowych, kontekstowych i dynamicznych treści, dostosowanych do indywidualnych potrzeb użytkownika.

## Znaczenie interaktywnych treści w marketingu

Kozon (2023) w artykule *Dlaczego interaktywne treści są ważne dla marketingu?* wskazuje, że istotne są personalizacja i angażowanie odbiorców poprzez interaktywne formaty (na przykład quizy, ankiety, dynamiczne rekomendacje), co znajduje potwierdzenie w pracach Wanxinga (2016), który badał strategie zwiększania efektywności interaktywnych reklam. W odniesieniu do algorytmów predykcyjnych wykorzystanie interaktywnych treści może poprawić jakość zbieranych danych o konsumentach i zwiększyć precyzję modeli predykcyjnych.

## Predykcja wskaźnika klikalności w reklamie internetowej

Z perspektywy analizy predykcyjnej w marketingu warto zwrócić uwagę na przegląd literatury dotyczący przewidywania wskaźnika klikalności (CTR) w reklamie internetowej, przedstawiony przez Yanwu i Panyu (2022). Autorzy omawiają różne modele stosowane do prognozowania prawdopodobieństwa kliknięcia przez użytkownika w konkretną reklamę, podkreślając znaczenie zaawansowanych algorytmów uczenia maszynowego w poprawie dokładności tych prognoz. Zastosowanie takich modeli pozwala na lepsze dostosowanie treści reklamowych do indywidualnych preferencji użytkowników, co w efekcie zwiększa efektywność kampanii marketingowych.

## Nowe formy budowania relacji z klientem w środowisku cyfrowym

Na tle współczesnych strategii marketingowych nie sposób pominąć nowych form budowania relacji z klientem, które opierają się na wykorzystaniu kanałów cyfrowych. Jak zauważa Kłosińska (2022), dynamiczny rozwój internetu sprzyja intensyfikacji działań, takich jak *content marketing*, *real-time marketing* czy komunikacja poprzez media społecznościowe i aplikacje mobilne. Wspólna cecha tych narzędzi to ich zdolność do budowania natychmiastowej, angażującej i personalizowanej interakcji z odbiorcą, co doskonale współgra z ideą marketingu predykcyjnego opartego na danych. Integracja zaawansowanych technologii analitycznych z interaktywnymi formami komunikacji wskazuje na rosnącą potrzebę tworzenia relacji opartych nie tylko na treści, ale także na czasie reakcji i dopasowaniu kontekstowym.

## Teoretyczne ujęcie zachowań nabywczych

Zrozumienie zachowań nabywców stanowi fundament skutecznych działań marketingowych, szczególnie w perspektywie rosnącej roli danych i personalizacji. Rosa i Perenc (2011) podkreślają, że procesy decyzyjne konsumentów są złożone i uwarunkowane wieloma czynnikami – od psychologicznych, przez społeczne, po ekonomiczne. W erze cyfrowej, gdzie dostęp do informacji jest niemal nieograniczony, konsumenci podejmują decyzje zakupowe w sposób bardziej świadomy, ale też podatni są na wpływ precyzyjnie kierowanych komunikatów marketingowych. Analiza mechanizmów zachowań nabywczych dostarcza podstaw do projektowania modeli predykcyjnych, które mogą skutecznie przewidywać potrzeby klientów oraz dostosowywać ofertę do ich indywidualnych preferencji.

## Ochrona konsumenta w świetle regulacji unijnych

Biorąc pod uwagę dynamikę rozwoju marketingu cyfrowego i personalizacji komunikacji z klientami, nie można pominąć kwestii prawnej ochrony konsumenta w środowisku transgranicznym. Jagielska (2010) zwraca uwagę na ewolucję ochrony konsumentów w prawie kolizyjnym Unii Europejskiej, wskazując na rosnącą potrzebę zapewnienia przejrzystości oraz przewidywalności zobowiązań umownych w relacjach przedsiębiorca–konsument. W dobie zautomatyzowanych rekomendacji i algorytmicznego przetwarzania danych zgodność działań marketingowych z unijnymi regulacjami dotyczącymi ochrony konsumenta staje się kluczowa. Regulacje te mają na celu nie tylko ochronę praw konsumentów, ale również wzmacnianie ich zaufania do cyfrowych kanałów sprzedaży, co przekłada się na skuteczność strategii budowania relacji z klientem.

## Mechanizmy działania algorytmów predykcyjnych

Zrozumienie działania algorytmów predykcyjnych jest kluczowe dla oceny ich skuteczności w marketingu opartym na danych. Tego typu algorytmy wykorzystują zaawansowane techniki statystyczne i uczenia maszynowego (*machine learning*) do analizowania dużych zbiorów danych w celu identyfikacji wzorców, które mogą posłużyć do przewidywania przyszłych zachowań konsumentów (James i in., 2013).

### Etapy przetwarzania danych predykcyjnych

Typowy proces budowania modelu predykcyjnego składa się z następujących kroków:

- **Zbieranie danych:** dane wejściowe pochodzą z wielu źródeł, między innymi historii zakupów, danych demograficznych, aktywności w mediach społecznościowych czy logów systemowych (Sivarajah i in., 2017).
- **Przygotowanie danych:** obejmuje czyszczenie, kodowanie, uzupełnianie braków oraz normalizację.
- **Uczenie modelu:** algorytmy uczą się na danych historycznych, tworząc modele predykcyjne, które identyfikują zależności między zmiennymi.
- **Testowanie i walidacja:** model jest oceniany na danych testowych, aby sprawdzić jego zdolność do generalizacji.
- **Wdrożenie i aktualizacja:** przeszkolony model jest implementowany w systemach marketingowych i okresowo aktualizowany w celu zachowania adekwatności (Choudhury, Harrigan, Soutar, 2021).

### Przykładowe techniki predykcyjne

W marketingu predykcyjnym wykorzystuje się wiele modeli, w tym:

- regresję logistyczną – do przewidywania prawdopodobieństwa konwersji;
- drzewa decyzyjne i lasy losowe (*random forest*) – do określania najważniejszych czynników wpływających na decyzje zakupowe;
- algorytmy grupowania (na przykład *k-średnich*) – do segmentacji klientów;
- sieci neuronowe – stosowane między innymi do generowania dynamicznych rekomendacji;
- filtrowanie kolaboratywne (*collaborative filtering*) – popularne w systemach rekomendacyjnych (Ricci, Rokach, Shapira, 2015).

Wybór konkretnego modelu zależy od rodzaju danych oraz celu biznesowego. Modele bardziej przejrzyste, takie jak regresja czy drzewa decyzyjne, umożliwiają lepszą interpretację, podczas gdy głębokie sieci neuronowe oferują większą skuteczność w dużych zbiorach danych kosztem przejrzystości (Zhang, Chen, 2020).

## Przykład zastosowania

W środowisku e-commerce algorytmy analizują między innymi historię przeglądania i zakupu, by w czasie rzeczywistym generować dopasowane rekomendacje produktowe. Systemy takie jak Amazon czy Netflix stosują hybrydowe podejście, łącząc filtrowanie kolaboratywne z analizą kontekstową i sieciami neuronowymi (Ricci, Rokach, Shapira, 2015).

## Wyzwania i ograniczenia

Chociaż algorytmy predykcyjne oferują znaczące korzyści, wiążą się również z pewnymi ograniczeniami:

- *overfitting* (nadmierne dopasowanie): model może zbyt dokładnie nauczyć się danych treningowych, co obniża skuteczność na danych nowych;
- *data drift*: zmiany w zachowaniach konsumentów mogą spowodować, że model stanie się nieaktualny (Sivarajah i in., 2017);
- brak przejrzystości działania: zaawansowane modele, szczególnie głębokie sieci neuronowe, są często trudne do zinterpretowania, co może wpływać na zgodność z regulacjami (Zhang, Chen, 2020).

Dlatego wdrożenie algorytmów powinno zawsze iść w parze z ich monitorowaniem, audytem i aktualizacją, szczególnie w kontekście danych osobowych i odpowiedzialności za podejmowane decyzje.

## Metodologia

W celu opracowania koncepcji badawczej niniejszego artykułu zastosowano podejście łączące analizę literatury oraz badanie empiryczne w postaci ankiety online. Główne ramy teoretyczne oparto na teoriach marketingu predykcyjnego, personalizacji treści oraz sztucznej inteligencji w marketingu. Szczególną uwagę poświęcono modelom uczenia maszynowego wykorzystywanym w analizie zachowań konsumentów oraz metodom segmentacji klientów stosowanym w marketingu cyfrowym. Dodatkowo w badaniu uwzględniono modele satysfakcji klienta opracowane przez Biesoka i Wyród-Wróbel (2016), co pozwoliło na ocenę związku między personalizacją marketingową a poziomem zadowolenia konsumentów.

Badanie, które oparte było na wskazanej wyżej ankiecie online, przeprowadzono na grupie 200 respondentów. Kwestionariusz składał się z pytań zamkniętych i otwartych, umożliwiających ocenę skuteczności personalizacji marketingowej oraz predykcji potrzeb konsumentów przez algorytmy. Badanie ankietowe przeprowadzono na grupie 200 dorosłych respondentów, zrekrutowanych w sposób celowo-przypadkowy za pośrednictwem grup społecznościowych w mediach społecznościowych (Facebook, LinkedIn). Rekrutacja trwała od 1 do 15 lutego 2025 roku.

Kryteriami włączenia były: ukończone 18 lat, zadeklarowana aktywność w zakupach online (minimum raz w miesiącu), zgoda na udział w badaniu.

Kryteriami wykluczenia były: brak aktywności zakupowej w internecie, niepełnoletność, odmowa zgody na przetwarzanie danych.

Zastosowany dobór nie miał charakteru probabilistycznego, co ogranicza możliwość pełnego uogólnienia wyników. W przyszłych badaniach rekomenduje się wykorzystanie bardziej złożonych metod doboru (na przykład warstwowego lub kwotowego), które zwiększą reprezentatywność próby.

Kwestionariusz składał się z 15 pytań, w tym 12 zamkniętych i trzech otwartych. Obszary badawcze obejmowały: percepcję działania algorytmów, zaufanie do rekomendacji, wpływ personalizacji na decyzje zakupowe oraz preferencje dotyczące treści marketingowych.

Respondenci zostali zrekrutowani w sposób celowo-przypadkowy, jak zostało to wyżej wskazane, głównie za pośrednictwem ogólnodostępnych grup tematycznych w mediach społecznościowych (Facebook, LinkedIn), skupiających użytkowników zainteresowanych technologiami, marketingiem i e-commerce. Udział w badaniu był dobrowolny, a jedynym kryterium włączenia była pełnoletność oraz zadeklarowana aktywność w zakupach online. Losowość nie była wsparta metodami doboru probabilistycznego, co stanowi ograniczenie badania.

Kwestionariusz ankiety zawierał łącznie 15 pytań – z czego 12 miało charakter zamknięty (między innymi skale Likerta, pytania jednokrotnego i wielokrotnego wyboru), a trzy były pytaniami otwartymi dotyczącymi subiektywnej oceny personalizacji. Zawartość kwestionariusza koncentrowała się wokół następujących obszarów: świadomość działania algorytmów SI, zaufanie do rekomendacji, trafność personalizacji, wpływ rekomendacji na decyzje zakupowe oraz preferencje dotyczące typów treści.

Choć artykuł odnosi się ogólnie do „marketingu cyfrowego”, analizowane treści dotyczyły głównie mediów społecznościowych, platform e-commerce oraz reklam internetowych (np. banerów, newsletterów). Respondenci nie byli pytani o konkretne platformy (np. Facebook, Allegro, Amazon), co stanowi ograniczenie poznawcze.

Wszystkie dane gromadzono anonimowo, a uczestnicy zostali poinformowani o celu badania oraz przetwarzaniu danych zgodnie z RODO. Ze względu na charakter badania eksploracyjnego i brak wykorzystania danych poufnych badanie nie wymagało formalnej akceptacji komisji etycznej. Należy jednak podkreślić, że brak walidacji narzędzia badawczego oraz nielosowy dobór próby ograniczają możliwość pełnego uogólnienia wyników.

W ramach przeglądu literatury zastosowano narracyjny typ przeglądu, zgodnie z podejściem opisanym w Green, Johnson i Adams (2006). Celem przeglądu było określenie aktualnego stanu wiedzy na temat zastosowań algorytmów predykcyjnych w marketingu cyfrowym, a także identyfikacja luk badawczych.

Proces selekcji obejmował przeszukiwanie trzech baz danych: Scopus, Web of Science oraz Google Scholar, w okresie listopad 2024 – styczeń 2025. Wykorzystano kombinacje słów kluczowych: *predictive marketing*, *AI in marketing*, *consumer behavior forecasting*, *personalization in digital marketing*.

Łącznie przeanalizowano 47 publikacji, w tym:

- 18 z bazy Scopus,
- 15 z Web of Science,
- 14 z Google Scholar.

Kryteriami włączenia były: (1) publikacje z recenzowanych czasopism naukowych lub renomowanych monografii, (2) opublikowane w latach 2018–2024, (3) dotyczące bezpośrednio zastosowania sztucznej inteligencji, algorytmów lub metod predykcyjnych w marketingu.

Kryteriami wykluczenia były: (1) źródła popularnonaukowe, blogi, (2) publikacje niemające charakteru empirycznego ani teoretycznego, (3) brak dostępu do pełnego tekstu.

Typologia przeglądu została oparta na klasyfikacji Paré i in. (2015) – niniejsza praca przyjmuje charakter teoretyczno-konceptualny, integrujący istniejące podejścia badawcze i praktyczne.

W zakresie analizy danych empirycznych zastosowano podejście ilościowe. Wyniki ankiety zostały poddane analizie statystycznej, obejmującej obliczenie średnich, odchyłeń standardowych oraz korelacji pomiędzy zmiennymi. Ponadto przeprowadzono analizę regresji w celu określenia wpływu personalizacji treści marketingowych na decyzje zakupowe oraz poziom satysfakcji klientów, co było zgodne z modelem zaproponowanym przez Biesoka i Wyród-Wróbel (2016).

Przyjęte podejście metodologiczne umożliwia kompleksowe spojrzenie na problematykę wykorzystania algorytmów predykcyjnych w marketingu, łącząc zarówno aspekty teoretyczne, jak i wyniki badań empirycznych.

## Wyniki

W niniejszym podrozdziale przedstawiono wyniki przeprowadzonego badania ankietowego dotyczącego percepcji i skuteczności algorytmów predykcyjnych w marketingu. Analiza obejmuje dane ilościowe uzyskane od 200 respondentów oraz podstawowe metryki statystyczne.

### Charakterystyka próby

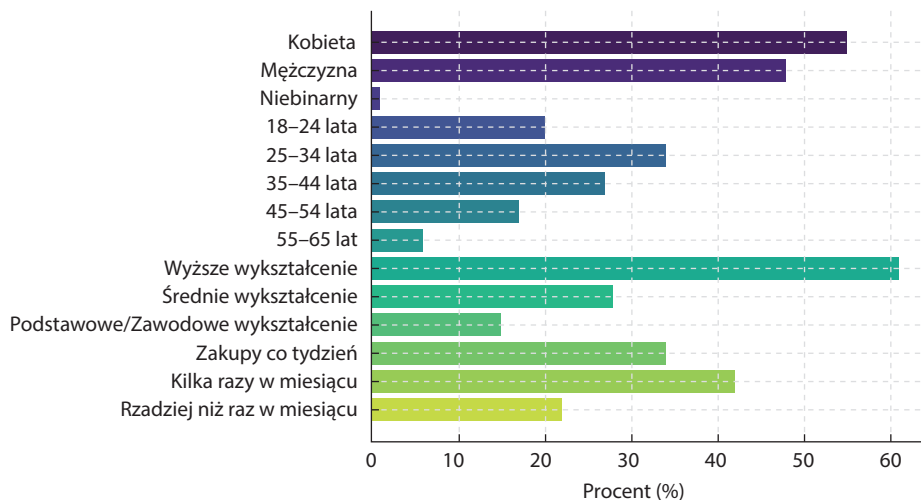
Badanie przeprowadzono na grupie 200 respondentów. Wśród uczestników:

- 52% stanowiły kobiety, 47% mężczyźni, 1% osoby niebinarne lub preferujące nieokreślanie swojej płci;
- średnia wieku wyniosła 34 lata (SD = 8,5), przy przedziale 18–65 lat;

- 61% badanych miało wykształcenie wyższe, 29% średnie, a 10% podstawowe lub zawodowe;
- 35% ankietyowanych dokonuje zakupów online co najmniej raz w tygodniu, 42% kilka razy w miesiącu, a 23% rzadziej niż raz w miesiącu.

Dla lepszego zobrazowania poniżej został umieszczony wykres, który zawiera wszystkie powyższe dane.

Charakterystyka demograficzna respondentów ankiety



**Wykres 1.** Charakterystyka demograficzna respondentów ankiety

Źródło: opracowanie własne.


## Świadomość istnienia algorytmów predykcyjnych

Jednym z pytań zawartych w ankiecie była prosta deklaracja: „Czy według Ciebie firmy wykorzystują algorytmy sztucznej inteligencji do personalizacji treści marketingowych?”. Pytanie to miało charakter rozpoznawczy i służyło ocenie deklarytywnego poziomu świadomości respondentów. Zgodnie z metodologią nie była to weryfikacja rzeczywistej wiedzy, a jedynie badanie postrzegania i subiektywnego przekonania uczestników. W przyszłych etapach badań planowane jest zastosowanie pytań otwartych o charakterze sprawdzającym, na przykład: „Co Twoim zdaniem decyduje o tym, jakie treści marketingowe widzisz w sieci?”.

Na powyższe pytanie 78% respondentów odpowiedziało twierdząco, 14% nie było pewnych, a 8% nie zdawało sobie sprawy z istnienia takich technologii.

W celu przedstawienia danych bardziej obrazowo poniżej został przygotowany wykres kołowy. Ukazuje on powyższe dane.

## Świadomość istnienia algorytmów predykcyjnych w marketingu



**Wykres 2.** Świadomość istnienia algorytmów predykcyjnych w marketingu

Źródło: opracowanie własne.

## Ocena trafności rekomendacji produktowych

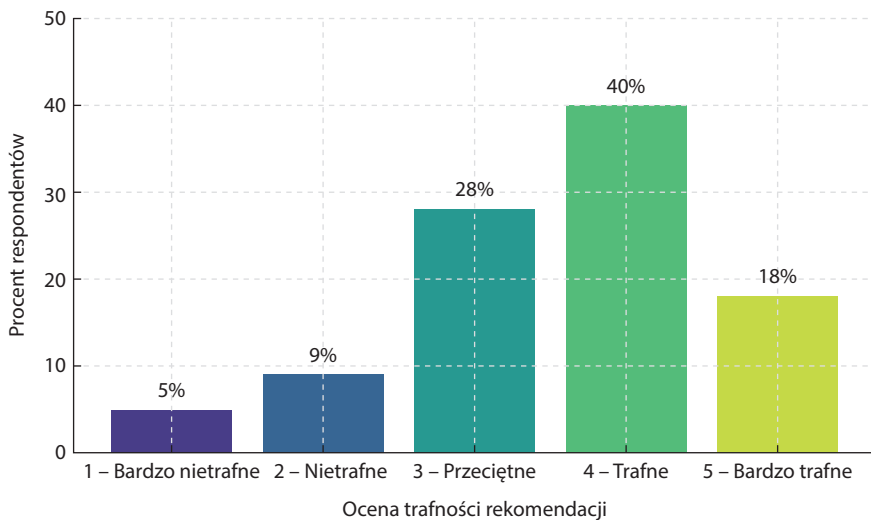
Respondenci zostali poproszeni o ocenę trafności rekomendacji marketingowych, które otrzymują w kanałach cyfrowych, takich jak media społecznościowe (np. Facebook, Instagram), platformy e-commerce (np. Allegro, Amazon), wyszukiwarki internetowe lub newslettery e-mailowe. Ocenie podlegały rekomendacje znane respondentom z ich codziennego korzystania z internetu, a nie przykładowe treści pokazane w kwestionariuszu.

Skala ocen wynosiła od 1 („bardzo nietrafne”) do 5 („bardzo trafne”). Średnia ocen wyniosła 3,9 (SD = 0,8), co sugeruje umiarkowanie pozytywny odbiór personalizacji treści marketingowych. Otrzymano następujące wyniki:

- 18% respondentów uznało rekomendacje za bardzo trafne (5),
- 40% za trafne (4),
- 28% za przeciętne (3),
- 9% za nietrafne (2),
- 5% za bardzo nietrafne (1).

W celu lepszego zaprezentowania danych poniżej został przygotowany wykres słupkowy, który ukazuje pozyskane wyniki badania.

## Ocena trafności spersonalizowanych rekomendacji produktowych



**Wykres 3.** Ocena trafności spersonalizowanych rekomendacji produktowych

Źródło: opracowanie własne.

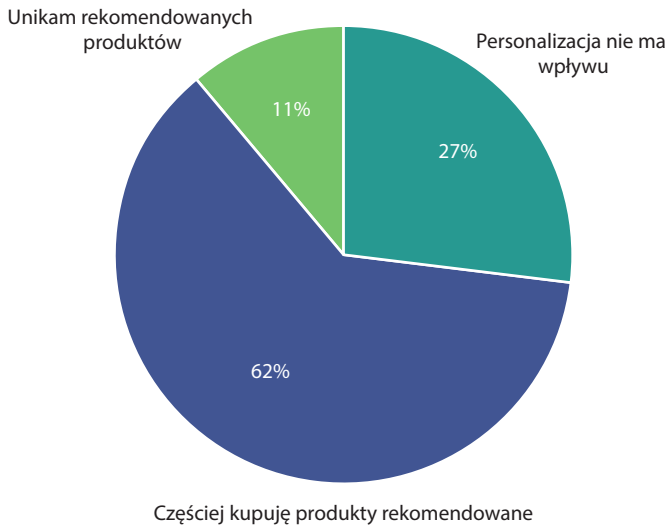
### Wpływ personalizacji na decyzje zakupowe

Zapytano uczestników, czy personalizacja ofert wpływa na ich decyzje zakupowe:

- 62% zadeklarowało, że częściej kupuje produkty, które były im rekomendowane;
- 27% uznało, że personalizacja nie ma wpływu na ich zakupy;
- 11% stwierdziło, że unika rekomendowanych produktów ze względu na wrażenie inwigilacji.

W celu pełniejszej prezentacji danych poniżej został przygotowany wykres, który ukazuje wyniki dotyczące wpływu personalizacji na decyzje zakupowe.

## Wpływ personalizacji ofert na decyzje zakupowe



**Wykres 4.** Wpływ personalizacji ofert na decyzje zakupowe

Źródło: opracowanie własne.

## Zaufanie do algorytmów predykcyjnych

Pytania dotyczące zaufania do algorytmów zadawano wszystkim respondentom, niezależnie od wcześniejszej deklaracji świadomości ich istnienia. Takie podejście umożliwiło porównanie odpowiedzi w zależności od deklarowanej świadomości, co pozwala lepiej zrozumieć związki między postrzeganiem, wiedzą i zaufaniem. Odpowiedzi osób, które nie były świadome istnienia algorytmów, zostały również uwzględnione w analizie jako istotne poznawczo. Na pytanie o zaufanie do algorytmów analizujących dane zakupowe i preferencje użytkowników:

- 55% badanych odpowiedziało, że ufa algorytmom w umiarkowanym lub wysokim stopniu;
- 32% ma neutralne podejście;
- 13% deklaruje niski poziom zaufania lub brak akceptacji dla takich technologii.

Poniżej został zaprezentowany wykres kołowy, który ukazuje dane dotyczące zaufania do algorytmów predykcyjnych.



**Wykres 5.** Zaufanie do algorytmów predykcyjnych

Źródło: opracowanie własne.

## Analiza korelacji

Przeprowadzono analizę korelacji między świadomością istnienia algorytmów a oceną trafności rekomendacji. Współczynnik korelacji  $r = 0,42$  ( $p < 0,01$ ) wskazuje na istotną, umiarkowaną zależność – osoby świadome działania algorytmów częściej oceniają ich skuteczność wyżej.

Ponadto stwierdzono pozytywną korelację między częstotliwością zakupów online a wpływem personalizacji na decyzje zakupowe ( $r = 0,35$ ,  $p < 0,05$ ), co sugeruje, że osoby częściej kupujące online są bardziej podatne na rekomendacje algorytmiczne.

Analiza danych wykazała, że personalizacja treści marketingowych ma istotny wpływ na decyzje zakupowe konsumentów, co potwierdzają modele satysfakcji klienta. W szczególności zaobserwowano istotną zależność między oceną trafności rekomendacji produktowych a poziomem zadowolenia klientów ( $r = 0,48$ ,  $p < 0,01$ ), co jest zgodne z wcześniejszymi badaniami dotyczącymi wpływu personalizacji na lojalność klientów.

Dodatkowo przeprowadzona analiza korelacji wykazała związek między częstotliwością zakupów online a skutecznością algorytmów predykcyjnych. Respondenci,

którzy częściej dokonywali zakupów online, oceniali algorytmiczne rekomendacje jako bardziej trafne, co pokrywa się z wnioskami płynącymi z badań nad digitalnymi zachowaniami konsumentów (Tarczydło, 2016).

Dodatkowo przeanalizowano związek pomiędzy wiekiem respondentów a ich oceną trafności rekomendacji. Stwierdzono umiarkowaną korelację odwrotną ( $r = -0,29$ ,  $p < 0,05$ ), co sugeruje, że młodsi respondenci częściej pozytywnie oceniają personalizowane rekomendacje. Może to wskazywać na większą otwartość młodszych konsumentów na algorytmiczne treści marketingowe i większe przyzwyczajenie do personalizacji w kanałach cyfrowych.

W perspektywie interaktywnych treści, zgodnie z ustaleniami Kozona (2023), badanie wykazało, że konsumenci preferują dynamiczne i angażujące formaty reklamy. 71% respondentów stwierdziło, że chętniej angażuje się w reklamy zawierające interaktywne elementy, co potwierdza ich znaczenie w nowoczesnych strategiach marketingowych.

Wyniki badania stanowią istotny wkład w rozwój wiedzy na temat skuteczności predykcyjnych algorytmów marketingowych i wskazują na konieczność dalszych badań nad ich zastosowaniem w różnych branżach oraz segmentach rynku.

## Dyskusje

Wyniki badania wskazują, że istnieje związek między postrzeganą personalizacją treści marketingowych a deklarowanym poziomem zaangażowania i decyzjami zakupowymi konsumentów. Analiza wykazała, że trafność rekomendacji produktowych ma pozytywną korelację z poziomem satysfakcji klientów, co jest zgodne z modelem satysfakcji klienta Biesoka i Wyród-Wróbel (2016). Wyniki te wskazują, że skuteczne algorytmy predykcyjne mogą zwiększać lojalność konsumentów oraz poprawiać ich doświadczenia zakupowe.

Odnosząc się do skuteczności zastosowań algorytmów predykcyjnych w marketingu, warto przywołać wnioski płynące z badań Davenport i Ronanki (2018), którzy analizując rzeczywiste wdrożenia sztucznej inteligencji w przedsiębiorstwach, wskazują, że same algorytmy nie gwarantują przewagi konkurencyjnej, jeśli nie towarzyszy im odpowiednia integracja danych oraz reorganizacja procesów decyzyjnych. Autorzy podkreślają, że największe korzyści biznesowe wynikają z połączenia analityki predykcyjnej z operacyjnymi systemami zarządzania relacjami z klientem (CRM) oraz platformami komunikacyjnymi. W świetle tych ustaleń zastosowania SI w marketingu należy postrzegać nie tylko jako technologiczną innowację, ale także jako impuls do transformacji całego modelu zarządzania doświadczeniem klienta.

Zbieżne wnioski formułują autorzy raportu *AI and Machine Learning in Predictive Analytics* (2023), podkreślając strategiczne znaczenie integracji danych z różnych kanałów i dynamicznego podejmowania decyzji marketingowych na podstawie

analiz predykcyjnych. W szczególności wykorzystanie danych psychograficznych, behawioralnych i kontekstowych pozwala na bardziej precyzyjne przewidywanie potrzeb klientów oraz tworzenie zindywidualizowanych ścieżek zakupowych.

Porównując wyniki z wcześniejszymi badaniami, potwierdzono wnioski Tarczydły (2016) dotyczące wzrostu oczekiwań konsumentów wobec spersonalizowanych treści. Badanie wykazało, że konsumenci preferują rekomendacje oparte na ich wcześniejszych interakcjach, co pokrywa się z ustaleniami dotyczącymi digitalnych zachowań użytkowników.

Jednym z kluczowych ustaleń jest również rola interaktywnych treści w zwiększaniu zaangażowania odbiorców, co znajduje potwierdzenie w badaniach Kozona (2023). Respondenci wskazali, że dynamiczne reklamy oraz angażujące treści pozytywnie wpływają na ich zainteresowanie ofertami, co sugeruje, że przyszłe strategie marketingowe powinny jeszcze bardziej wykorzystywać personalizowane formy komunikacji.

Dodatkowo, jak zauważa Patil (2024), generatywna sztuczna inteligencja (GenAI) umożliwia tworzenie dynamicznych i wysoce spersonalizowanych treści marketingowych w czasie rzeczywistym. Zdolność GenAI do samodzielnego projektowania komunikatów reklamowych, dopasowanych do kontekstu użytkownika, może znacząco zwiększać skuteczność kampanii i zaangażowanie odbiorców. W świetle tych ustaleń łączenie tradycyjnych algorytmów predykcyjnych z modelami generatywnymi stanowi obiecujący kierunek dla rozwoju marketingu cyfrowego.

Dodatkowo wyniki badania korespondują z ustaleniami Łęgowskiego (2017), który podkreśla znaczenie budowania długoterminowych relacji z klientem jako determinanty lojalności i satysfakcji konsumenta. Jak wykazały przeprowadzone analizy, konsumenci są bardziej skłonni do lojalności wobec marek, które oferują spersonalizowane treści i dynamicznie reagują na ich potrzeby. Wskazuje to na istotną rolę marketingu predykcyjnego w strategiach budowania długofalowych relacji z klientami, co potwierdza zasadność stosowania nowoczesnych technologii w zarządzaniu doświadczeniem klienta.

Jednocześnie należy zaznaczyć, że trzecia hipoteza badawcza – dotycząca różnic w skuteczności algorytmów predykcyjnych w zależności od branży oraz typu produktu lub usługi – nie została zweryfikowana empirycznie. Z uwagi na uniwersalny charakter kwestionariusza i brak pytań identyfikujących branżę, w której funkcjonują respondenci, analiza nie objęła tego aspektu. Stanowi to istotne ograniczenie badania i wskazuje kierunek dla przyszłych analiz uwzględniających kontekst branżowy i sektorowy.

Choć badanie dostarcza interesujących spostrzeżeń, jego wnioski należy traktować ostrożnie, ze względu na ograniczenia metodologiczne, w tym nielosowy dobór próby oraz deklaracyjny charakter danych. Przede wszystkim próba badawcza obejmowała jedynie 200 respondentów, co może ograniczać możliwość uogólniania

wyników na szerszą populację. Ponadto analiza opierała się na deklaracyjnych odpowiedziach uczestników, co niesie ryzyko błędu subiektywności.

W kontekście implikacji wyniki sugerują konieczność dalszych badań nad skutecznością algorytmów predykcyjnych w różnych branżach oraz ich wpływem na długoterminową lojalność klientów. Wskazane jest także pogłębienie analizy dotyczącej etycznych aspektów wykorzystania danych konsumentów, szczególnie w odniesieniu do prywatności i transparentności algorytmów marketingowych.

Podsumowując, badanie dostarcza wartościowych wniosków na temat efektywności algorytmów predykcyjnych w marketingu, podkreślając ich rolę w poprawie doświadczeń zakupowych konsumentów. Jednakże dalsze badania są konieczne, aby w pełni zrozumieć długoterminowe konsekwencje stosowania takich technologii.

Warto również podkreślić, że trzecia hipoteza badawcza – dotycząca różnic w skuteczności algorytmów predykcyjnych w zależności od branży oraz typu oferowanego produktu lub usługi – nie została zweryfikowana w toku niniejszego badania. Zrezygnowano z tego elementu analizy ze względu na ogólny charakter narzędzia badawczego, które nie zawierało pytań pozwalających na identyfikację branżową respondentów. Ograniczenie to wynikało z eksploracyjnego charakteru badania i przyjętego celu poznawczego. Niemniej jednak uznajemy tę lukę za istotną i wskazującą na potrzebę kontynuacji badań, uwzględniających specyfikę sektorową i branżową zastosowań algorytmów predykcyjnych.

## Ograniczenia badania

Należy zauważyć, że część pytań ankietowych miała charakter deklaracyjny i nie weryfikowała rzeczywistej wiedzy respondentów. Przykładem jest pytanie o świadomość istnienia algorytmów predykcyjnych – miało ono na celu określenie subiektywnego postrzegania, a nie faktycznego zrozumienia mechanizmów personalizacji. Ponadto ocena trafności rekomendacji oparta była na własnych doświadczeniach uczestników, co niesie ryzyko rozbieżności interpretacyjnych. W kolejnych etapach badań planowane jest zastosowanie bardziej złożonych narzędzi, w tym pytań weryfikujących wiedzę i przedstawiania respondentom konkretnych przykładów treści do oceny.

## Podsumowanie

Przeprowadzone badanie wskazuje, że marketing oparty na danych – w szczególności zastosowanie algorytmów predykcyjnych – może skutecznie wspierać personalizację treści, zwiększając zaangażowanie konsumentów oraz ich skłonność do

podejmowania decyzji zakupowych. Respondenci w większości pozytywnie oceniali trafność rekomendacji, a ich percepcja personalizacji korelowała z częstotliwością zakupów oraz poziomem satysfakcji.

Wyniki potwierdzają również istotną rolę treści interaktywnych jako czynnika wzmacniającego skuteczność algorytmów predykcyjnych i angażującego odbiorców. Odpowiada to wcześniejszym ustaleniom z zakresu digitalnych zachowań konsumenckich oraz badań nad doświadczeniem klienta.

Należy jednak podkreślić, że jedna z hipotez badawczych – dotycząca różnic w skuteczności algorytmów w zależności od branży – nie została zweryfikowana z uwagi na ogólny charakter narzędzia badawczego. Jest to istotne ograniczenie, które powinno zostać uwzględnione w przyszłych pracach.

Coraz większe znaczenie zyskują również generatywne modele AI (np. GAN, LLM), które nie tylko analizują dane historyczne, ale także symulują przyszłe reakcje konsumentów. Jak wskazano w przeglądzie *Generative AI for Consumer Behavior Prediction* (2024), narzędzia te mogą służyć do testowania różnych wariantów treści i przewidywania ich odbioru jeszcze przed wdrożeniem kampanii, co otwiera nowe możliwości personalizacji i optymalizacji strategii marketingowych.

Z perspektywy dalszych badań zasadne wydaje się pogłębienie analizy długoterminowego wpływu personalizacji na lojalność klientów oraz eksploracja różnic branżowych w odbiorze algorytmicznych rekomendacji. Równie istotna pozostaje kwestia etyczna, w tym zagadnienia związane z przejrzystością działania algorytmów i ochroną danych osobowych.

Podsumowując: marketing predykcyjny ma znaczny potencjał dla budowania wartościowych relacji z klientami. Jego skuteczność powinna być jednak analizowana w sposób wieloaspektowy, uwzględniający zarówno zmienne technologiczne, jak i społeczne oraz regulacyjne.

## Bibliografia

- Biesok G., Wyród-Wróbel J. (2016). *Modele satysfakcji klienta*. Warszawa: Difin.
- Choudhury M.M., Harrigan P., Soutar G.N. (2021). „Algorithmic marketing: The impact of AI on consumer decision-making”. *Journal of Business Research*, 124, s. 390–400.
- Davenport T.H., Ronanki R. (2018). „Artificial Intelligence for the Real World”. *Harvard Business Review*, 96 (1), s. 108–116.
- European Commission (2021). Proposal for a Regulation laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). COM/2021/206 final.
- Floridi L., Cowls J., Beltrametti M. i in. (2018). „AI4People – An Ethical Framework for a Good AI Society: Opportunities, Risks, Principles, and Recommendations”. *Minds and Machines*, 28 (4), s. 689–707.
- Green B.N., Johnson C.D., Adams A. (2006). „Writing narrative literature reviews for peer-reviewed journals: secrets of the trade”. *Journal of Chiropractic Medicine*, 5 (3), s. 101–117. DOI: 10.1016/S0899-3467(07)60142-6.

- Jagielska M. (2010). *Ewolucja ochrony konsumenta w prawie kolizyjnym Unii Europejskiej w zakresie zobowiązań umownych*. Warszawa: Wydawnictwo Naukowe PWN.
- James G., Witten D., Hastie T., Tibshirani R. (2013). *An Introduction to Statistical Learning*. New York–Heidelberg–Dordrecht–London: Springer.
- Kłosińska J. (2022). *Nowe formy budowania relacji z klientem w Internecie za pomocą takich narzędzi jak content marketing, real-time marketing, aplikacje mobilne, portale społecznościowe, komunikacja video*. Łódź: Akademia Techniczna im. Jarosława Dąbrowskiego.
- Kozon T. (2023). *Dlaczego interaktywne treści są ważne dla marketingu?* BoringOwl. Pobrane z: <https://boringowl.io/blog/dlaczego-interaktywne-tresci-to-przyszlosc-marketingu> (dostęp: 19.08.2025).
- Lee M., Fernandez J. (2023). *AI and Machine Learning in Predictive Analytics: Revolutionizing Business Strategies through Big Data Insights*. EBSCOhost: Business Source Complete. Pobrane z: <https://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=160387423> (dostęp: 19.08.2025).
- Łęgowski S. (2017). „Budowanie relacji z klientem jako determinanta lojalności i satysfakcji konsumenta na rynku telefonii komórkowej”. *Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach*, 328, s. 93–105.
- Paré G., Trudel M.-C., Jaana M., Kitsiou S. (2015). „Synthesizing information systems knowledge: A typology of literature reviews”. *Information & Management*, 52 (2), s. 183–199. DOI: 10.1016/j.im.2014.08.008.
- Patil D. (2024). *Generative Artificial Intelligence in Marketing and Advertising: Advancing Personalization and Optimizing Consumer Engagement Strategies*. SSRN. Pobrane z: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=5057404](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5057404) (dostęp: 19.08.2025).
- Ricci F., Rokach L., Shapira B. (2015). *Recommender Systems Handbook*. New York: Springer.
- Rosa G., Perenc J. (red.) (2011). *Zachowania nabywców*. Szczecin: Wydawnictwo Naukowe Uniwersytetu Szczecińskiego.
- Rószkiewicz M. (2016). „Metody predykcji w analitycznym Consumer Relation Management na potrzeby marketingu relacji”. *Roczniki Kolegium Analiz Ekonomicznych*, 40, s. 123–138.
- Sivarajah U., Kamal M.M., Irani Z., Weerakkody V. (2017). „Critical analysis of Big Data challenges and analytical methods”. *Journal of Business Research*, 70, s. 263–286. DOI: 10.1016/j.jbusres.2016.08.001.
- Tarczydło B. (2016). *Konsument digitalny i jego zachowania. Przegląd badań*. Rzeszów: Wydawnictwo Uniwersytetu Rzeszowskiego.
- Wanxing D. (2016). „The Exploratory Research of the Effect Communication Model and Effect Improving Strategy of Interactive Advertising”. *The International Journal of Multimedia & Its Applications*, 8 (1), s. 19–34.
- Yanwu Y., Panyu Z. (2022). „Click-Through Rate Prediction in Online Advertising: A Literature Review”. *Information Processing & Management*, 59 (2), 102853.
- Zhang Y., Chen X. (2020). „Explainable Recommendation: A Survey and New Perspectives”. *Foundations and Trends in Information Retrieval*, 14 (1), s. 1–101. DOI: 10.1561/15000000066.
- Zhou H., Kumar R. (2024). „Generative AI for Consumer Behavior Prediction: Techniques and Applications”. *Journal of Artificial Intelligence Research and Applications*, 9 (1), s. 45–68. DOI: 10.1016/j.jaira.2024.01.003.