

# **ARTIFICIAL INTELLIGENCE I MACHINE LEARNING - WYKORZYSTANIE ALGORYTMÓW I ANALIZ DO PROFILOWANIA I PERSONALIZACJI PRZEKAZÓW DYSTRYBUOWANYCH W SIECI**

**Konrad Liszczyk**

Uniwersytet Ekonomiczny we Wrocławiu  
Katedra Inteligencji Biznesowej w Zarządzaniu

## **Wprowadzenie**

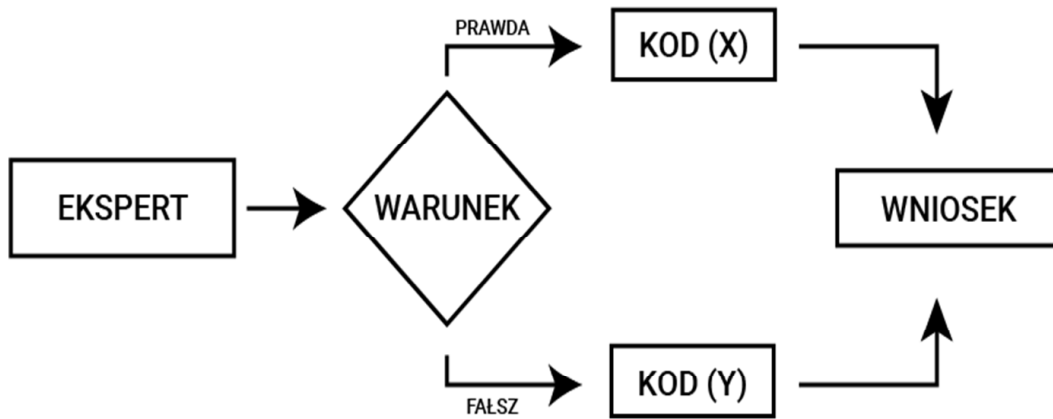
Rekomendacje i polecenia są podstawą udanych relacji biznesowych od początku zachodzących między ludźmi interakcji handlowych. Personalizacja przekazów tak, by trafiały w odpowiednim czasie do odpowiednich grup docelowych, była jedną z kluczowych barier, które cyfryzacja i automatyzacja miały za zadanie usprawnić. Zwyczajna ekstrakcja oraz agregacja danych w oparciu o wiedzę eksperta nie dawała wystarczających efektów przekładanych na konkretny ekwiwalent w postaci mierzalnej wartości. W fazie początkowej rozdział ma za zadanie ukazać występujące w schematyczny sposób relatywne różnice, jakie występują między decyzjami podjętymi przez eksperta a decyzjami opartymi na wynikach i prognozach reprezentowanych przez algorytmy uczenia maszynowego. Następnie ukazane są algorytmy samego uczenia wykorzystywane do pracy z personalizacją przekazów, w tym przekazów marketingowych obecnych w sieci z konkretnym podziałem na charakter uczenia się algorytmów. Bezpośrednio z tematyką skorelowane są mechanizmy zarówno uczenia maszynowego występujące w nomenklaturze związanej z informatyzacją, jak i ich wykorzystaniem w stosunku do systemów rekomendacji i personalizacji przekazów. Część poświęcona analizom ma za zadanie zobrazować modele analiz, na których opierają się współczesne algorytmy wykorzystywane do dystrybucji przekazów. Jednym z odrębnych tematów jest personalizacja behawio-

ralna ukierunkowana w stronę samego użytkownika oraz segmentów, które reprezentuje. Ukazany model ma zobrazować przepływ danych od pozyskania ich u źródła aż po dystrybucję w sieci. W tej części rozdziału widoczny jest podział na rekomendacje oparte na użytkowniku oraz w kolejnej części na rekomendacje oparte na produkcie; podrozdział ten wskazuje typy rekomendacji wspierane algorytmami. Ostatni podrozdział poświęcony jest kluczowemu tematowi związanemu z dywagacjami na temat wykorzystania uczenia maszynowego w praktyce, czyli ograniczeń związanych z wykorzystaniem sztucznej inteligencji, ponadto ukazane są wady wynikające z nadmiernego wykorzystania prognoz algorytmów oraz nieodpowiedniego dopasowania ich zarówno do segmentu rynku, jak i konkretnego działu w organizacji wynikające z korelacji między inteligencją sztuczną a inteligencją ludzką.

## **Decyzje eksperta a decyzje wspierane algorytmem**

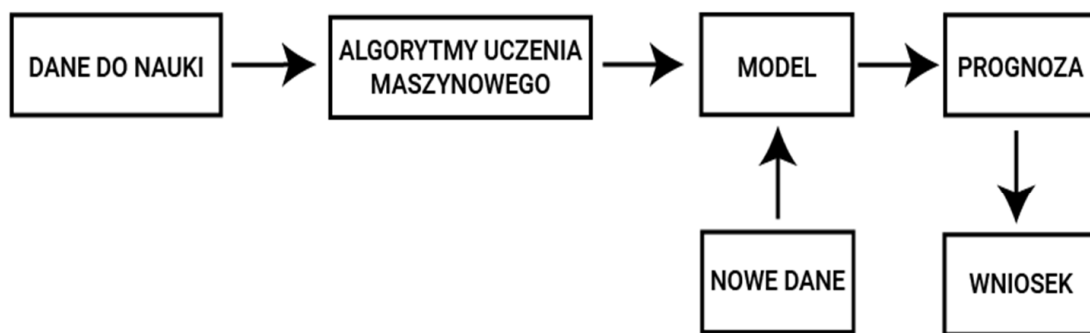
Obecnie postępująca fala cyfryzacji wymusza na ekspertach z danej dziedziny dostosowanie się do reguł dyktowanych przez rynek sterowany technologią. Decyzje eksperckie wyróżniają się przede wszystkim poprzedzającymi je analizami związanymi z badanym tematem. Obecnie wiele segmentów rynku, a w nich konkretne branże, w których decyzyjność eksperta jawi się w późniejszym przełożeniu na procesy biznesowe, a co ważniejsze na bezpośrednie wyniki finansowe organizacji, stara się wdrażać elementy stałe, będące kwantyfikowalnym wsparciem dla ekspertów w danych dziedzinach. Decyzje biznesowe podejmowane w toku procesów zachodzących w organizacjach są przede wszystkim obarczone wysokim ryzykiem, w tym głównie ryzykiem niepowodzenia niosącym za sobą długofalowe skutki. Poniższy schemat funkcjonowania procesu decyzyjnego eksperta przedstawia uproszczony model. Ekspert z wybranej dziedziny w bloku pierwszym staje przed warunkiem, czy twierdzenie jest prawdziwe, czy fałszywe. Jednym z determinantów jest ograniczona możliwość wyboru eksperta, a tym samym zbyt duża ilość zmiennych stanowiących bezpośrednie obciążenie dla podmiotu, mogących skutkować na dalszym prawidłowym procesie decyzyjnym. Zarówno względem twierdzenia prawdziwego, jak i fałszywego powstaje kod X oraz Y będący implikacją warunku. Na podstawie obu powstaje wniosek z postępującego procesu. Wniosek może wpływać pozytywnie, jak i negatywnie oraz nieść daleko idące konsekwencje. Blok „WNIOSEK” zdefiniowany został celowo, jako spójny dla wariantu boolowskiego, tak by zobrazować w schematyczny sposób, że decyzja zarówno prawdziwa, jak i fałszywa w modelu niesie konkretny i mierzalny wniosek. W przypadku fałszu, jak i prawdy może być on pozytywny dla dalszego procesu decyzyjnego zachodzącego w organizacji.

Marketing cyfrowy, będący jedną z pochodnych marketingu rozumianego jako proces planowania realizacji założonych koncepcji, od początku funkcjonowania na rynku oparty jest na zbiorach danych, będących podstawą decyzyjności w branży. Obecnie branże związane z tworzeniem marketingu digitalnego oraz jego analizą wiążą się bezpośrednio z przetwarzaniem, agregacją oraz interpretacją danych będących implikacją wcześniejszych procesów zachodzących w sieci.



**Rysunek 3.1. Proces decyzyjny wsparty wiedzą eksperta**

Źródło: Opracowanie własne na podstawie (Błażewicz 2021, s. 32-35)



**Rysunek 3.2. Proces decyzyjny wsparty algorytmem uczenia maszynowego**

Źródło: Opracowanie własne na podstawie (Błażewicz 2021, s. 135-138)

Powyższy schemat (*Rysunek 3.2*) znacząco różni się od schematu przedstawionego na *Rysunku 3.1* z uwagi na całkowicie odmienny charakter procesu. Rola eksperta została domyślnie pominięta w projektowaniu, gdyż jego rola jest poza schematem w stosunku do elementów powyższego modelu. Proces definiowany jest przez same dane, które w znacznej ilości przygotowywane są do procesu nauczania przez algorytmy uczenia maszynowego. Dane do nauki implementowane są do algorytmów stanowiących fundament procesu, na podstawie których powstaje model danych, a ten stale zasilany jest nowymi strumieniami danych, niezbędnymi do prawidłowego procesu uczenia się algorytmu. Implikacją owego procesu jest informacja, gdzie celowo użyta została w pierwszej kolejności prognoza, a następnie wniosek, z uwagi na fakt, że prognoza bez odpowiedniej interpretacji pozostanie nieproduktywna. Właśnie w początkowej fazie ekspert wprowadza dane, za których wiarygodność jest odpowiedzialny oraz w fazie końcowej interpretuje je i nadaje użyteczność biznesową. W obu przypadkach, zarówno w procesie przedstawionym na *Rysunku 3.1*, jak i na *Rysunku 3.2*, kluczowa jest interpretacja prognozy przez eksperta. Oba modele różnią się znacząco pod kątem elementów procesu i występującymi podmiotami, jednakże wynik obu procesów pozostaje niezmienny – powstaje wniosek, który ma nieść mierzalny skutek biznesowy, niezbędny do dalszego funkcjonowania organizacji.

Względem dziedziny marketingu, w tym marketingu cyfrowego, widoczne są znaczące różnice w procesie decyzyjności. Wspomniana pochodna marketingu zintegrowana jest przede wszystkim z pojęciami zachowania użytkowników w sieci, tworzenia grup i segmentów odbiorców oraz zmiennymi wynikającymi ze schematów interakcji w sieci. Na podstawie analizy obu powyższych schematów widoczna jest różnica wynikająca ze złożoności procesu. Widoczny jest również stopień ograniczeń występujących u eksperta, dotyczący decyzyjności, który jawi się poprzez:

- brak możliwości śledzenia niestandardowych reakcji użytkowników, w tym: akcji, zdarzeń oraz decyzji podejmowanych w czasie rzeczywistym;
- skończoną liczbę możliwych do utworzenia segmentów odbiorców, które podane zostaną późniejszym analizom;
- wrażliwość na zmienne, takie jak: cena, trendy, upodobania, sezonowość;
- brak możliwości ustalenia korelacji występujących w czasie rzeczywistym oraz skończona liczba korelacji wynikająca z powiązań między zdarzeniami w danym czasie;
- ograniczona możliwość testowania w czasie rzeczywistym: testowanie w warunkach laboratoryjnych;
- podatność na subiektywne interpretacje ekspertów.

Ostatni punkt, odnoszący się do subiektywizmu w fazie końcowej, występuje zawsze ze strony eksperta uczestniczącego w procesie. Obecnie schematy decyzyjne oparte na algorytmach umożliwiają przede wszystkim ograniczenie pola błędu wynikającego z samego procesu podejmowania decyzji. Rekomendacje i polecenia stosowane w sieci przez algorytmy bywają dopasowane nie tylko do grupy odbiorców o podobnych zainteresowaniach, ale nierzadko potrafią spersonalizować przekaz jeden do jednego, podając użytkownikowi oczekiwaną informację, by finalnie uzyskać od niego konwersję, rozumianą jako pożądaną interakcję zdefiniowaną przez nadawcę treści, tym samym zyskując przewagę rynkową. W rzeczywistości opartej wyłącznie na intuicji i wiedzy nabytej w przeszłości eksperci nie są w stanie dopasowywać przekazu i dystrybuować treści w sposób zbliżony do tego, w jaki robią to algorytmy z wykorzystaniem analiz oraz elementów uczenia maszynowego.

## **Algorytmy uczenia maszynowego w zastosowaniu rekomendacji**

Uczenie maszynowe znane nam pod dzisiejszą postacią to przede wszystkim obszar sztucznej inteligencji złożony z algorytmów – ciągów czynności ówczynie zdefiniowanych, które niezbędne są do pozyskania wiedzy – wniosku, będącego implikacją procesu przetwarzania danych. Każdorazowo, gdy wynik na nowo przetwarzany jest przez algorytm, dostarczane są nowe dane wyjściowe, a sam wynik skłania się ku dokładniejszym результатам. Uczenie maszynowe w swoim rozumowaniu skupia się przede wszystkim na działaniach kategoryzacyjnych, które prowadzą do porządkowania oraz segregacji, a także kalibracji informacji wejściowych, identyfikacji wzorców i korelacji występujących pomiędzy danymi, wykrywaniu anomalii, a przede wszystkim prognozowaniu i przewidywaniu wyników na podstawie ówczynie zdefiniowanych wzorców. Uczenie maszynowe w systemach

rekomendacyjnych również oparte zostało na czterech kluczowych dla niego rodzajach. W każdym z przytoczonych rodzajów doszukać się możemy również bezpośredniego wpływu procesów rekomendacyjnych:

- 1) **Uczenie nadzorowane** – algorytm dostaje gotowy zestaw danych, ówczesnie przygotowanych; zadaniem jest utworzenie reguł w danym zbiorze, łączące konkretny wynik z danymi wejściowymi. Mając dane wejściowe, będzie można przewidzieć konkretny wynik. Zadaniem algorytmu jest nauczenie się przewidywania prawidłowej odpowiedzi oraz generalizacja występujących przypadków. Uczenie nadzorowane wykorzystywane jest przy segmentacji klientów. Na podstawie danych opisanych algorytm przygotowuje profile użytkowników o podobnych danych behawioralnych oraz demograficznych.
- 2) **Uczenie nienadzorowane** – algorytm pracujący na danych nieoznaczonych. Szuka on schematów i reguł w danych wejściowych, gdzie istotny nie jest wynik, a skupienie się na schematach i korelacjach występujących w bazie. W uczeniu nienadzorowanym, co istotne, występuje zestaw metod, czyli analiza skupień oraz składowych głównych. Analiza składowych odrzuca cechy nie niosące ze sobą informacji, natomiast analiza skupień segmentuje zbiory według atrybutów w celu dalszych eksploracji. Wykorzystywany w analizie koszyka zakupowego (asocjacji), w tym przede wszystkim w systemach rekomendacji produktowych takich jak cross oraz up selling, będących podstawą do maksymalizacji zysków konwersji w sieci.
- 3) **Uczenie półnadzorowane** – hybrydowy model algorytmu wykorzystujący dane opisane, jak i nieopisane, zwykle w małych ilościach. System uczy się reguł na danych opisanych, a następnie na danych nieopisanych proponuje rozwiązania i tworzy wzorce. Wykorzystywany przy rozpoznawaniu obrazu, mowy i dźwięku.
- 4) **Uczenie wzmocnione** – algorytm z określonym ówczesnie celem. W toku pracy algorytm otrzymuje wskazówki, czy metody przybliżają, czy oddalają go od celu. Wykorzystywany jest przy tworzeniu spersonalizowanych scenariuszy zakupowych dla użytkowników, a także przy tworzeniu tak zwanych ścieżek-podróży użytkownika (customer journey), odpowiadających za subiektywne doznania, opierając się na danych historycznych ze ścieżek zakupowych użytkowników zakończonych pożądanym efektem zwanym konwersją.

Każdy z wymienionych rodzajów uczenia maszynowego posiada znamieny wpływ na rozwój systemów rekomendacyjnych wspartych algorytmami, tym samym stanowi swoisty trzon dywagacji oraz płaszczyznę rozwoju w kierunku jeszcze głębszych analiz zachowania konsumentów w sieci oraz systemów rekomendacyjnych.

## **Mechanizmy uczenia maszynowego – zastosowanie w systemach rekomendacji**

Algorytmy wykorzystywane w uczeniu maszynowym, będące mechanizmem fundamentalnym dla sztucznej inteligencji, opierają się na jasno ustrukturyzowanym podziale. Sztuczna inteligencja rozumiana jest jako obszar nauk opartych na przetwarzaniu informacji, na który składają się uczenie maszynowe, uczenie głębokie oraz sieci neuronowe (Gregor, Kaczorowska-Spychalska 2020, s. 26-30).

Przegląd literatury, w której zawarta została tematyka wykorzystania obszaru SI, pozwolił zobrazować w sposób szczegółowy jej potencjalne zastosowania w rozwijających się gałęziach szeroko rozumianego przedsiębiorstwa 4.0. Celem analizy było zbadanie pod kątem użyteczności ostatnich dwóch elementów prac związanych z systemami rekomendacji oraz dystrybucją personalizowanych treści w sieci, czyli uczenia głębokiego (deep learning) oraz sieci neuronowych. Uczenie głębokie, czyli zestaw technik, które pozwalają trenować wielopoziomowe sieci neuronowe, odznacza się długim czasem oczekiwanej odpowiedzi. Dane z etapu poprzedniego stają się danymi wejściowymi do etapu następnego, na co bezpośrednio przedkłada się zapotrzebowanie na ogromne ilości danych algorytmów uczących się, które dostarczane są wielokanałowo, przykładowo z mediów społecznościowych, transakcji użytkowników, wszelkich akcji wykonanych w sieci oraz zewnętrznych baz, których podłożem i miejscem agregacji są systemy klasy ERP, hurtownie danych czy systemy zarządzania bazą klientów (Customer Relationship Management) (Błażewicz 2021, s. 150).

Analizując serwisy takie jak Amazon.com oraz Netflix.com, światowych potentatów technologicznych w sprzedaży dóbr i usług oraz tworzeniu wysoce cyfrowych oraz zdynamizowanych rozwiązań, zauważyć można, że spopularyzowały one zastosowanie systemów rekomendacji. Rozwiązania wspomnianych korporacji pozwalają z dużym prawdopodobieństwem przewidzieć, czym użytkownik może być zainteresowany, opierając się przede wszystkim na zagregowanych danych historycznych opartych na zachowaniach i wyborach użytkowników. Platformy ponadto stosują algorytmy uczenia głębokiego skorelowane bezpośrednio z informacjami dotyczącymi produktów – tak jest w przypadku Amazon.com, natomiast w przypadku Netflix.com opierające się na informacjach o filmach i serialach. Implikacja procesu w fazach początkowych musi być korelowana z wynikami badań z dziedziny psychologii, tak aby wynik algorytmu pokrywał się z nawykami konsumentami.

Uczenie głębokie może służyć do usprawnienia rekomendacji w wysoce złożonych środowiskach, takich jak modelowanie zainteresowań muzycznych lub preferencji odzieżowych, gdzie wiele zmiennych składa się na końcową decyzję użytkownika, natomiast wynik w oparciu o naturalne zachowania człowieka może być kalibrowany w dowolnym momencie.

Kolejny mechanizm, czyli najmniejsza jednostka zawierająca się w obszarze sztucznej inteligencji – sieci neuronowe, składa się z warstw węzłów, obejmujących warstwę wejściową, jedną lub więcej warstw ukrytych oraz warstwę wyjściową. Zasada funkcjonowania mówi o minimalizacji interwencji ludzkich i ingerowaniu w powstanie wyniku końcowego. Sieci neuronowe, upodobnione do ludzkich synaps, uczą się i stają dokładniejsze, co umożliwia błyskawiczne klasyfikowanie danych. W systemach rekomendacji stosowane są przede wszystkim rekurencyjne sieci neuronowe. Wyróżnia się je w oparciu o pętle informacji zwrotnych (sprzężenia zwrotnego), gdzie informacje uzyskane na wyjściu trafiają ponownie na wejście sieci, zamykając się we wspomnianym sprzężeniu (Telikani i in. 2021, s. 161).

Zastosowanie wspomnianego rodzaju sieci znajduje ujście głównie przy wykorzystaniu danych w szeregach czasowych do przewidywania przyszłych wyników, w tym prognozowania sprzedaży oraz prognozowania wyników finansowych na rynkach kapitałowych, gdzie ilość zmiennych, która musi zostać ujęta, jest ciągle powielana. Ponadto sieci neuronowe w systemach rekomendacji wykorzystywane są w rozpoznawaniu takich elementów jak obrazy, mowa i dźwięki. W szczególności rozpoznawanie mowy opiera się na konwertowaniu języka maszynowego na język naturalny, co generuje ciągle powstawanie nowych połączeń między „synapsami”. Jedną z najbardziej rozpoznawalnych dla ludzkości oraz najbardziej rozbudowanych pod kątem technologicznym sieci neuronowych jest wyszukiwarka internetowa Google, której algorytm oparty jest na wyszukiwaniu haseł przez użytkowników.

Zarówno uczenie głębokie, jak i sieci neuronowe to mechanizmy uczenia maszynowego nasycone rozwiązaniami ukierunkowanymi w stronę optymalizacji treści oraz jej dystrybuowania. Analiza pokazała również, że mechanizmy uczenia zawierają się w sobie wzajemnie, co może obrazować często nakładanie się pewnych wzorców oraz paradygmatów zawartych w uczeniu maszynowym. Systemy rekomendacji są płaszczyzną, która jest i będzie rozwijana przez największe koncerny technologiczne na świecie, jednakże postępujący proces cyfryzacji oraz kreuujący się model przedsiębiorstw 4.0 pozwolą mniejszym podmiotom gospodarczym czerpać, a także tworzyć nowe trendy z dziedziny zastosowania uczenia maszynowego oraz sztucznej inteligencji w sieci, zwłaszcza w obszarze rekomendacji oraz dystrybucji treści na platformach sprzedażowych.

## **Analizy wsparte algorytmami – wykorzystanie w praktyce**

Sednem dystrybucji informacji w sieci odgórnie spersonalizowanych przez system są analizy będące trzonem projektowania algorytmów. Obecnie wyróżnia się trzy kluczowe analizy wynikające z wykorzystania algorytmów uczenia maszynowego w systemach rekomendacji w sieci. Są nimi przede wszystkim:

- Analiza koszykowa (asocjacja) – szczegółowa analiza danych transakcyjnych, z dziedziny Data Mining. Analiza scentralizowana jest na szukanie powiązań i korelacji współwystępowania ze sobą dóbr, ale także anomalii występujących w danych łączeniach oraz tworzenie tablic rekomendacyjnych konkretnych dóbr dla odpowiednich segmentów użytkowników. Analiza wsparta najczęściej jest algorytmem apriori. Sensem analizy jest odkrycie schematów między występującymi kategoriami. Algorytm apriori nie wskazuje jedynie relacji między produktami, ale dzięki swojej konstrukcji pozwala odrzucić nieznaczące dane, wyznaczając procentowo prawdopodobieństwo występowania jednostki. Asocjacja stosowana jest przede wszystkim w rekomendacjach produktowych, ich bezpośrednią bazę tworzą konwersje użytkowników wynikające z zakupów oraz odwiedzin danych witryn.

- Analiza behawioralna – szczegółowa analiza danych demograficznych oraz geolokalizacyjnych, badanie aktywności użytkowników między transakcjami oraz powtarzalność ścieżek. Uwzględnia zainteresowania i zachowania konsumentów w celu zrozumienia ich indywidualnych preferencji. Analiza wsparta algorytmami SI dostarcza gotowych segmentów zaangażowanych użytkowników celem dopasowania treści reklamowych (wynik asocjacji jako kryterium). Analizuje wzorce, dostarcza zalecenia 1 do 1 oraz rekomendacje skierowane do sprzedaży krzyżowej i sprzedaży nastawionej na maksymalizację wartości koszyka zakupowego (cross/up sell).
- Analiza sentymentu – rozpoznawanie opinii użytkowników do wdrażania automatycznych rekomendacji. Jej zadaniem jest wyszukać i zaklasyfikować w wypowiedzi słowa naznaczone emocjonalnie, także takie, które świadczą o stanie emocjonalnym autora. Jest to metoda statystyczna oparta na uczeniu z nadzorem oraz bez, do której wykorzystywane są techniki takie jak drzewa decyzyjne czy sieci neuronowe. Analiza pozwala zobrazować, jakie treści wpływają pozytywnie na tendencje zakupowe użytkowników, oraz kierować odpowiednie przekazy do konkretnych segmentów odbiorców.

Kluczowe do wykorzystania analiz w kooperacji z algorytmami jest dopasowanie odpowiednich zbiorów danych, które finalnie dadzą oczekiwany wynik, a tym samym staną się użyteczne dla samego eksperta. Mimo wysokiego stopnia zaawansowania statystycznego powyższych analiz dobór baz i ich indeksacja należy do eksperta w danej dziedzinie. Od niego również zależy ostateczna dystrybucja i lokowanie algorytmów wspartych analizami. Kluczowe pozostaje połączenie inteligencji sztucznej z inteligencją ludzką, zarówno w fazie początkowej, jak i końcowej procesów.

## **Profilowanie behawioralne wsparte uczeniem maszynowym**

Profilowanie behawioralne stosowane jest od kilku lat w systemach automatyzacji marketingu online (ang. marketing automation). Systemy tej klasy stały się podwalinami do pracy nad algorytmami dedykowanymi do rekomendacji oraz personalizacji, a także dystrybucji treści w sieci. Obecnie algorytmy uczenia maszynowego odpowiednio zagregowane oraz interpretowane pozwalają zrozumieć dogłębnie potrzeby odbiorców. Dążenie do personalizacji „doskonałej”, opartej na najmniejszych szczegółach, pozwala w dużym stopniu śledzić nie tylko listę obejrzanych przez użytkownika dóbr w sieci, ale też informacje na temat wszystkich sprawdzanych przez niego parametrów i wyświetlanych szczegółów z uwzględnieniem danych historycznych. Na tej podstawie wyłaniane są cechy wspólne, unikalne dla każdego klienta, pozwalające na dokładne dopasowanie oferty do segmentu klientów najbardziej zainteresowanych danym dobrem. Śledzone aktywności zawierają się w takich akcjach, jak:

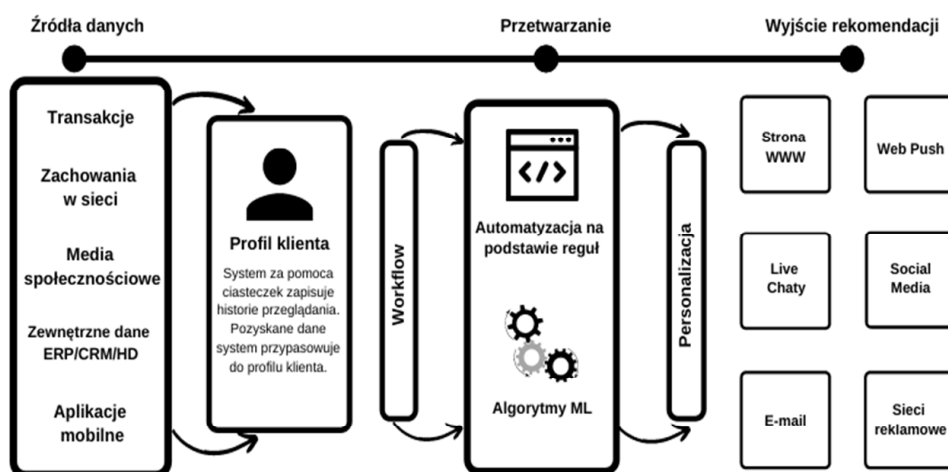
- wyświetlanie użytkownikowi konkretnego elementu na stronie, w tym produktów, reklam graficznych i tekstowych oraz cen i rabatów z nimi związanych;
- najechanie kursorem na element oraz stopień przewinięcia strony w odniesieniu do urządzenia, z którego korzysta użytkownik (desktop/mobile), a także w zależności od systemu operacyjnego, z którego użytkownik korzysta w danym momencie oraz korzystał wcześniej;



- zmiana wariantu produktu w czasie rzeczywistym, rozumiana jako wszelkie interakcje użytkownika związane z danym dobrem, w tym takie zdarzenia jak zmiana koloru, rozmiaru, przedziału cenowego czy marki;
- dodanie dobra do list identyfikowanych jako przestrzeń bazodanowa, którą użytkownik może zagospodarować do gromadzenia produktów, takowe przestrzenie to ulubione produkty bądź koszyki sklepowy;
- śledzenie filtrów i wyszukiwanych fraz przez użytkownika, zarówno w czasie rzeczywistym, jak i z uwzględnieniem danych historycznych.

Zebrane dane pozwalają tworzyć wysoce spersonalizowane rekomendacje, ówczesznie poparte analizami stanowiącymi fundament działania algorytmów uczenia maszynowego. Po odpowiednio zdefiniowanym oraz przygotowanym procesie (Rysunek 3.2) personalizowane rekomendacje w szczególności objawiają się następująco:

- Reagowanie na interakcje, dobieranie przez algorytm danego dobra, zgodnie z wcześniejszymi upodobaniami oraz jego prezentacja w najodpowiedniejszej dla odbiorcy formie. Algorytm sam uczy się, jakie ustawienie produktu na wirtualnej półce sklepowej oraz w jakiej kompozycji strony najbardziej sprzyja finalizacji zakupu przy danym kliencie, kończąc go definiowaną ówczesznie konwersją. Obecnie konwersje postrzegane są w skali mikro oraz makro, gdzie mikrokonwersje stanowią akcje związane z ekosystemem sprzedażowym rozumianym jako niebezpośrednia sprzedaż dobra, w tym kliknięcie maila, przeczytanie wpisu blogowego czy dodanie produktów do koszyka; to organizacja sama ustala cele. Konwersje w skali makro to pożądane akcje wykonane przez użytkownika stanowiące podstawę do kwantyfikowalnych wyników finansowych takich jak zakup produktów lub usług.
- Remarketing, forma reklam graficznych, jak i tekstowych, będących odzwierciedleniem zebranych danych przez algorytm i odpowiednio skorelowanych ze sobą informacji o atrybutach danych dóbr oraz przedstawienie ich użytkownikowi w formach reklam graficznych i tekstowych.



**Rysunek 3.3. Profilowanie użytkowników z wykorzystaniem reguł przetwarzania uczenia maszynowego**

Źródło: Opracowanie własne na podstawie (Błażewicz 2021, s. 61)

Jedną z pochodnych personalizacji jest budowa systemów oceniających zarówno produkty, jak i profile klientów. Scoring produktowy pozwala skorelować cechy produktów, ich ceny oraz warianty, tak aby dopasować je do konkretnych segmentów użytkowników, nadając im odpowiednie oceny – punkty o przypisanej ówczesznie wadze. Warunkiem powstania dopasowanego profilu klienta, jak i dopasowania odpowiedniego produktu jest wykorzystanie asocjacji i analiz behawioralnych zastosowanych w algorytmach uczenia maszynowego, tak by baza segmentów oraz baza produktów odpowiednio korelowały się u wyjścia procesu, czyli komunikatu marketingowego ukazywanego użytkownikowi. Oceny natomiast pozwalają nadawać priorytety przekazów oraz określać potencjał zakupowy wyznaczonych segmentów użytkowników.

Powyższy graf (*Rysunek 3.3*) reprezentuje uproszczony proces personalizacji, który wspomagany jest algorytmami uczenia maszynowego. Podstawę modelu stanowią źródła danych, które rozumiane są jako zarówno wszelkie interakcje użytkownika w sieci, jak i dane historyczne ówczesznie zebrane o nim w bazach zewnętrznych (systemach klasy ERP, CRM). System dopasowuje i przypisuje do danego klienta odpowiednio zeskalowane dane, tworząc jego profil wzbogacony o atrybuty nabyte w toku przetwarzania danych, przykładowo takie jak wiek, płeć, orientacja, zainteresowania, geolokalizacja. Na ich podstawie następuje proces przetwarzania, czyli „karmienia” danymi algorytmu ówczesznie opartego na przygotowanych analizach. Wyniki procesu dopasowywane są do kanału dystrybucji rekomendacji oraz nadawane są mu odpowiednie treści. Owymi kanałami mogą być przykładowo strony WWW, powiadomienia typu push, czyli powiadomienia działające w tle, ze szczególnym naciskiem na kanały mobilne, media społecznościowe, reklamy funkcjonujące w systemie Real Time Bidding – aukcyjnej konkurencji o pozycję treści w wyszukiwarce, czaty prowadzone na żywo, oparte na rozwiązaniach z technologii SI czy maile marketingowe.

## Typy rekomendacji produktowych wsparte sztuczną inteligencją

Podstawą prawidłowego funkcjonowania rekomendacji jest ich odpowiednia typologia zarówno według segmentacji profili użytkowników, jak i segmentacji produktowej. W poprzednim fragmencie schemat profilowania użytkowników skupiony był na pozyskaniu, przetworzeniu oraz prezentacji danych w oparciu o zachowania użytkowników. Segmentowanie produktów wsparte algorytmami, względem późniejszego dopasowania i szukania korelacji występujących między nimi a użytkownikami, opiera się na czterech kluczowych typach rekomendacji:

- Najczęściej kupowane razem – dobra nabyte już wcześniej przez użytkownika (analiza danych historycznych) lub przez innych, podobnych do niego profilem znajdujących się w tym samym segmencie. Na ich podstawie rekomendowane są dobra podobne lub komplementarne. Najprostsza z metod rekomendacji, wymagająca ingerencji algorytmu w stopniu podstawowym, jednakże równocześnie jedna z najskuteczniejszych. Najczęściej kupowane razem opierają się na klasycznych modelach asocjacyjnych. Analizowany typ rekomendacji skupia się bardziej na samych koszykach klientów oraz wynikach konwersji aniżeli na danych związanych z behawioryzmem oraz demografią użytkownika.

- Najczęściej oglądane razem – występująca również, jak w poprzednim typie, analiza koszykowa, która pozwala użytkownikom oszczędzić czas i energię. Opiera się na ukazaniu razem najczęściej kupowanych ze sobą dóbr. Celem jest tworzenie systemu rekomendacji wspieranego zagregowanymi oraz skorelowanymi danymi w taki sposób, aby na wirtualnych półkach produkty najczęściej oglądane oraz klikane były w stosunkowo bliskiej odległości, aby przede wszystkim zminimalizować rozproszenie się użytkownika, a tym samym aby użytkownik nie wykonywał zbędnych akcji.
- Wspólne filtrowanie – zestawienie: cech wyświetlanych, kupowanych produktów oraz profili użytkowników, stworzenie tym samym swoistej macierzy. Celem są rekomendacje występujące na podstawie podobieństw użytkowników i produktów. Złożona analiza wielu zmiennych, do której wykorzystywane są techniki uczenia głębokiego. Jeden z typów rekomendacji produktowych skorelowanych w sposób głęboki z segmentami oraz profilami konkretnych użytkowników. Macierz rekomendacyjna uwarunkowana jest wieloma zmiennymi, które implikują wyniki udoskonalające się z każdą nową rekomendacją podawaną jako wynik przez algorytm.
- Najczęściej kupowane po obejrzeniu innego – na podstawie analizy produktów w czasie rzeczywistym użytkownikowi proponowany jest podobny lub niepodobny, lecz mogący się wpasować do profilu, produkt. Algorytm musi w odpowiednim momencie zlokalizować powiązania między produktami i użytkownikami oraz występujące między nimi podobieństwa, tworząc swoistą macierz w czasie rzeczywistym. Dane są przechowywane, by móc uczyć się dalej zachowań określonej grupy docelowej, jednakże konkretnym wynikiem są rekomendacje podawane w systemie Real Time.

Wszystkie wspomniane typy rekomendacji pozwalają przede wszystkim agregować dane, a następnie tworzyć na ich podstawie określone schematy, co stanowi trzon funkcjonowania prawidłowo dobranych algorytmów uczenia maszynowego. Określone typy są w pewien sposób podobne do siebie, opierają się na podobnych modelach i analizach, jednakże sam wynik rekomendacji oraz personalizacji treści różni się w danym momencie, gdy jedną z kluczowych dyferencji jest kanał dystrybucji treści. Aby odpowiednio wykorzystać potencjał modeli wspartych algorytmami, niezbędne są decyzje eksperckie. Faza uczenia, a następnie „dokarmiania” algorytmu odpowiednimi danymi są czasochłonne, a wyniki dopracowywane są regularnie przez samą maszynę uczącą się. Z uwagi na wielokanałowe strumienie danych dopływające stale do algorytmów proces prognozowania wyniku stale się doskonali.

### **Sztuczna inteligencja a inteligencja ludzka – ograniczenia związane z wykorzystaniem algorytmów w profilowaniu przekazów marketingowych w sieci**

Mimo występujących wyraźnych korzyści płynących z zastosowania systemów wspartych algorytmami uczenia maszynowego w procesie personalizacji oraz rekomendacji przekazów marketingowych w sieci, obecnie dalej istnieje wiele przeszkód, które wyraźnie przemawiają za ograniczaniem wykorzystania algorytmów

lub ograniczają je do niezbędnego minimum, lub nawet do zera. Jednym z bazowych ograniczeń jest to, że systemy nadal pozostają w znacznym stopniu zależne od człowieka. Sam proces projektowania algorytmów wymaga od człowieka określenia sposobów pozyskiwania wiedzy, która generowana przez system powinna podlegać kontroli i ocenie człowieka, według podanych przez niego kryteriów, a następnie końcowej interpretacji. Bazą są przede wszystkim poprawnie opanowane i rozumiane systemy eksperckie oraz poprawnie wykorzystywane systemy wnioskowania. Kolejną obiekcją są koszty wdrożenia i użytkowania, które obecnie są bardzo wysokie, co związane jest zarówno z kosztami wynikającymi z infrastruktury technologicznej, jak i zatrudnienia specjalistów z dziedziny analizy danych. W kwestii użyteczności obszarów sztucznej inteligencji w branżach wymagających wysokiej kreatywności oraz indywidualizmu ich nadmierne lub niepotrzebne wykorzystanie może prowadzić do blokady procesów prorozwojowych w organizacji.

Wykorzystanie eksperckiej wiedzy w danej dziedzinie, zespolone z wynikami działania algorytmów, zapewni wykorzystanie pełnego potencjału obszaru sztucznej inteligencji w biznesie oraz przełożenie go na korzyści dla danej organizacji. Ludzka inteligencja skorelowana z inteligencją sztuczną nie tylko w systemie rekomendacji, ale również w innych, szeroko rozumianych aspektach nauki, takich jak ekonomia czy medycyna, dają wymierne korzyści, które mogą bezpośrednio prowadzić do ulepszenia życia końcowych odbiorców.

## Podsumowanie

W toku dywagacji związanych z personalizacją wspartą algorytmami uczenia maszynowego pojawiły się pojęcia nowo powstałe, zarówno dla płaszczyzny naukowej, w tym w badaniach natury teoretycznej, jak i na płaszczyźnie rynkowej, rozumianej jako praktyki użytkowania. Obecna automatyzacja zadań, a także oczekiwania otrzymania szybkiego, precyzyjnego wyniku stawiane są w przedsiębiorstwach jako fundament funkcjonowania na dynamicznie rozwijającym się rynku. W epoce, w której zagregowane dane są warte więcej niż surowce naturalne, można pokusić się o stwierdzenie, że dystrybuowane treści będą docierały do nas w maksymalnie spersonalizowanych przekazach, a nasze decyzje zakupowe będą przewidywane z niezwykłą dokładnością, w oparciu o zagregowane dane historyczne. Obszar sztucznej inteligencji wykorzystujący algorytmy uczenia maszynowego znalazł bez wątpienia zastosowania właśnie w analizach konsumentów w sieci, a w węższym rozumowaniu odnalazł płaszczyznę przede wszystkim pozwalającą zbierać, agregować oraz prawidłowo interpretować dane o zachowaniach użytkowników. Artykuł daje możliwość kontynuacji i rozwijania tematu, zwłaszcza w oparciu o profilowanie behawioralne, szczególnie z uwagi na aspekt psychologiczny badania użytkowników oraz ich doświadczeń, ale także z racji typów samych rekomendacji wspartych algorytmami, jak również wykorzystania otrzymanych prognoz w celach biznesowych. Jedną z konkluzji fundamentalnych pracy jest dostrzeżenie korelacji działania wiedzy eksperta i wiedzy pozyskanej z systemów wspieranych algorytmami, udowadniając, że kooperacja pomiędzy inteligencją ludzką oraz sztuczną zapewni prawdziwą i mierzalną wartość, zarówno dla organizacji, jak i użytkowników końcowych.

## Literatura

1. Artun O., Levin D. (2015), *Predictive Marketing: Easy Ways Every Marketer Can Use Customer Analytics and Big Data*, Wiley, New Jersey.
2. Barutcu M.T. (2017), *Big Data Analytics for Marketing Revolution*, „Journal of Media Critiques”, Vol. 3(11), s. 163-171.
3. Błażewicz G. (2016), *Rewolucja z Marketing Automation. Jak wykorzystać potencjał Big Data*, Wydawnictwo Naukowe PWN, Warszawa.
4. Błażewicz G. (2021), *Marketing Automation w kierunku sztucznej inteligencji*, Wydawnictwo Naukowe PWN, Warszawa.
5. Campbell J.D., Sadas S. (2020), *From Data to Action: How Marketers Can Leverage AI*, Business Horizons, Indianapolis.
6. Daugherty P.R., Wilson H.J. (2018), *Human + Machine: Reimagining Work in the Age of AI*, Harvard Business Press, Boston.
7. Dutko M. (red.) (2016), *Biblia e-biznesu 2. Nowy Testament*, Onepress, Gliwice.
8. Gentsch P. (2018), *AI in Marketing, Sales and Service: How Marketers without a Data Science Degree Can Use AI*, Springer, Frankfurt.
9. Gregor B., Kaczorowska-Spychalska D. (red.) (2020), *Technologie cyfrowe w biznesie. Przedsiębiorstwa 4.0 a sztuczna inteligencja*, Wydawnictwo Naukowe PWN, Warszawa.
10. Grigsby M. (2019), *Marketing Analytics. Jak skutecznie korzystać ze statystyk, analiz, modeli i Big Data w marketingu*, Wydawnictwo Naukowe PWN, Warszawa.
11. Hebb D.O. (2012), *The Organization of Behavior: A Neuropsychological Theory*, Taylor & Francis, London.
12. <http://customerexperiencematrix.blogspot.com/> (dostęp: 24.09.2021).
13. <https://analyticsindiamag.com/top-data-science-aitrends-to-watch-out-for-in2021/> (dostęp: 10.09.2021).
14. <https://business2community.com/marketing/whats-hype-around-hiper-personalization01045882> (dostęp: 13.09.2021).
15. <https://github.com/tommyod/Efficient-Apriori> (dostęp: 17.09.2021).
16. <https://marketing-automation.pl> (dostęp: 17.09.2021).
17. <https://statystyka.az.pl/analiza-skupien/analiza-koszykowa.phpd> (dostęp: 23.09.2021).
18. Ryan D., Jones C. (2011), *Najlepsze kampanie marketingu cyfrowego*, Wolters Kluwer, Warszawa.
19. Siegel E. (2018), *Prognozuj, kto kliknie, kupi, skłamię lub umrze. Wprowadzenie do analityki predykcyjnej*, MT Biznes, Warszawa.
20. Surma J. (2017), *Cyfryzacja życia w erze Big Data. Człowiek, biznes, państwo*, Wydawnictwo Naukowe PWN, Warszawa.
21. Telikani A., Tahmassebi A., Banzhaf W., Gandomi A. (2021), *Evolutionary Machine Learning: A Survey*, ACM Computing Surveys, New York.
22. Vaughan D. (2021), *Umiejętności analityczne w pracy z danymi i sztuczna inteligencją*, Helion, Gliwice.
23. Wodecki A. (2021), *Sztuczna inteligencja we współczesnych organizacjach. Jak autonomiczne systemy mogą wpływać na firmy, modele biznesowe i rynki?*, Wydawnictwo Naukowe PWN, Warszawa.
24. Wrycza S., Maślankowski J. (red.) (2019), *Informatyka ekonomiczna. Teoria i zastosowania*, Wydawnictwo Naukowe PWN, Warszawa.
25. Zalewska M., Zalewski W. (2012), *Zastosowanie metody drzewa decyzyjnego w analizie problemów makroekonomicznych*, „Economics and Management”, nr 4, s. 58-69.