

Wykorzystanie eksperymentów i technik rekomendacji w e-commerce do optymalizacji cen

Jak zoptymalizować cenowo sieć sklepów firmowych z pieczywem i wyrobami cukierniczymi? Sklepy zlokalizowane są zarówno przy ulicach, w centrach handlowych, jak i w kioskach na stacjach, przystankach tam, gdzie gromadzą się ludzie. Ustalenie właściwych cen ma kluczowe znaczenie dla utrzymania konkurencyjności oraz rentowności piekarni, ponieważ wpływa bezpośrednio na wielkość sprzedaży, marżę brutto oraz postrzeganie piekarni przez klientów.



Wojciech Moszczyński

Tradycyjne, intuicyjne podejście do wyceny może prowadzić do różnych błędów, które mogą spowodować utratę marży lub udziału w rynku. Dlatego coraz częściej sięga się po metody data science, aby tworzyć scenariusze cenowe (warianty strategii cenowych) i oceniać ich potencjalny wpływ na kluczowe wskaźniki biznesowe. Oparte na danych analizy pozwalają przetestować różne założenia „na sucho” – np. symulując podwyżkę czy obniżkę cen wybranych produktów – zanim zostaną one wdrożone w realnych sklepach. Dzięki temu decyzje cenowe można dostosować do reakcji rynku i uniknąć kosztownych błędów. W niniejszym opracowaniu przedstawiamy, jak wykorzystać dane historyczne, modelowanie statystyczne i narzędzia analityczne do opracowywania strategii cenowych oraz jak oceniać ich skutki dla sprzedaży, marży, indeksów cenowych i wizerunku cenowego firmy. Omówimy również wpływ polityki cenowej na percepcję klientów i pozycjonowanie marki, a także powiązanie decyzji cenowych z zarządzaniem zapasami (*replenishment*) i optymalizacją zaopatrzenia sklepów.

Dane historyczne i analiza popytu

Metody data science przy tworzeniu polityki cenowej bazują na zgromadzonych danych historycznych opisujących wielkość sprzedaży w czasie w kontekście określonych cen. Historyczne dane sprzedażowe z poszczególnych sklepów i produktów pozwalają zidentyfikować sezonowość popytu, trendy wzrostowe lub spadkowe, a także reakcje sprzedaży na wcześniejsze zmiany cen czy działania promocyjne. Analiza szeregów czasowych (np. metodami statystycznymi takimi jak modele ARMA czy ARIMA) lub technik uczenia maszynowego (np. modele prognostyczne) umożliwiają prognozowanie popytu na kolejne okresy na podstawie dotychczasowych wzorców. Aby takie prognozy były wiarygodne,




dane muszą być dokładne, kompletne i aktualne – niepełne lub przestarzałe informacje historyczne mogą prowadzić do błędnych predykcji popytu. W praktyce firmy integrują dane sprzedażowe z danymi zewnętrznymi, czyli tzw. danymi kontekstowymi (np. informacjami o cenach konkurencji czy wskaźnikach makroekonomicznych, dniach tygodnia czy stosowanych przez firmę aktualnych promocji), by lepiej zrozumieć kontekst rynkowy. Na przykład uwzględnienie cen konkurencji pomaga ocenić czy spadek sprzedaży był wynikiem zbyt wysokiej ceny względem innych ofert na rynku, czy też skutkiem ogólnego spadku popytu. Analiza danych historycznych stanowi punkt wyjścia do modelowania zależności ceny i sprzedaży – zanim zaplanuje się nowe scenariusze cenowe, trzeba zrozumieć dotychczasowe zależności między ceną a wolumenem sprzedaży dla kluczowych produktów. Modele predykcyjne bazują na różnych informacjach kontekstowych. Tak więc możemy zaobserwować, że największa sprzedaż pieczywa występuje w poniedziałki, środy i piątki, słodczyce najlepiej schodzą w soboty, a pojawienie się nieopodal nowej piekarni znacznie obniżyło obroty w naszym sklepie. Czynniki kontekstowe mają często bardzo dużą moc predykcyjną, dlatego też zbieranie tych danych jest bardzo ważne przy ustalaniu przyszłej wielkości popytu, która bezpośrednio wpływa na wysokość cen produktów. Jak pamiętamy cena jest relacją między popytem a podażą. Im więcej produktów jest na rynku tym cena jest niższa. Tak więc pojawienie się nowej piekarni nieopodal powoduje wzrost podaży przez co konieczne jest obniżenie ceny, w przeciwnym razie nasze towary nie będą sprzedane.

Elastyczność cenowa i modelowanie popytu

Jednym z najważniejszych pojęć w analizie cen jest **elastyczność cenowa popytu**, określająca czułość wielkości sprzedaży na zmianę ceny. Mówiąc najprościej: elastyczność cenowa

mówi o ile procent zmieni się wolumen sprzedaży, gdy cena produktu wzrośnie lub spadnie o określony procent. Jeśli po podniesieniu ceny sprzedaż wyraźnie spada, mówimy, że popyt na dany produkt jest wysoko elastyczny cenowo; jeśli zmiana ceny prawie nie wpływa na wolumen sprzedaży, popyt jest nieelastyczny. W praktyce elastyczność oblicza się jako stosunek procentowej zmiany wielkości sprzedaży do procentowej zmiany ceny. Przykładowo, wzrost ceny o 10% skutkujący spadkiem sprzedaży o 20% oznacza elastyczność wynoszącą -2 (wartość ujemna odzwierciedla odwrotną zależność między ceną a popytem). Znajomość tego wskaźnika jest bezcenna przy podejmowaniu decyzji cenowych, ponieważ pozwala przewidywać, jak klienci mogą zareagować na podwyżkę lub obniżkę cen i jak taka zmiana wpłynie na przychody oraz marżę. W analizie data science elastyczność dla poszczególnych produktów lub kategorii można oszacować na podstawie danych historycznych za pomocą modelu regresji. Często przeprowadza się też **testy cenowe** – kontrolowane eksperymenty (np. w wybranych sklepach lub przez ograniczony czas) – aby empirycznie zmierzyć reakcję popytu na zmianę ceny o określony zakres. Wyniki analizy elastyczności pozwalają sklasyfikować produkty na wrażliwe cenowo i niewrażliwe, co jest pomocne w segmentacji asortymentu. Przykładowo, produkty pierwszej potrzeby (jak podstawowe rodzaje pieczywa) mogą cechować się wysoką elastycznością – klienci szybko zareagują na podwyżkę ceny spadkiem zakupów lub przeniesieniem się do konkurencji. Z kolei unikalne wyroby cukiernicze, takie jak wymyślnie dedykowane torty okolicznościowe dostępne tylko w naszej cukierni, mogą być mniej elastyczne (klienci kupią je mimo wyższej ceny ze względu na brak bezpośrednich substytutów). Modelowanie popytu polega na zbudowaniu funkcji lub modelu przewidującego poziom sprzedaży w zależności od ceny oraz innych czynników (np. dnia tygodnia, pogody, lokalizacji sklepu, aktywności promocyjnych). Taki model – czy to prosty ekonometryczny, czy złożony uczenia maszynowego – służy następnie do symulowania różnych scenariuszy cenowych i przewidywania ich skutków. Mówiąc najprościej, istnieją usługi lub produkty, które mają popyt sztywny. Niezależnie od tego jaka jest cena klienci będą skłonni dokonać zakupu. Najbardziej spektakularnym przykładem popytu sztywnego są usługi pogrzebowe. Z drugiej strony istnieją takie produkty, których elastyczność cenowa ma charakter krańcowo elastyczny. Przykładem takiego produktu są lody. Jeżeli gałka lodów będzie kosztowała 5 zł, to taka cena będzie występowała we wszystkich cukierniach w miasteczku. Podniesienie ceny gałki do 6 zł spowoduje drastyczny spadek sprzedaży. Mając dużo sklepów i duży asortyment można przeprowadzić testy elastyczności popytu. Możemy na przykład podnieść cenę określonych produktów o nieznaczną wartość i sprawdzić jaka będzie reakcja klientów w średnim okresie, np. tygodnia. Bardzo ważne jest, żeby eksperyment prowadzić w okresie



kilku dni, ponieważ zazwyczaj klienci jeżeli są przyzwyczajeni do zakupów w określonym sklepie kupują nie patrząc na cenę. Klienci muszą uświadomić sobie zmianę ceny. Wtedy będzie możliwe zaobserwowanie reakcji na zmianę. Należy wspomnieć o tym, że taki eksperyment jest kosztowny, ponieważ podnoszenie ceny powoduje spadek sprzedaży. Spadek sprzedaży na pewno odbije się na rentowności firmy. Niestety badania trochę kosztują i możemy potem zrekompensować sobie utracone przychody wprowadzając efektywny system zarządzania cenami dla całego asortymentu. Błędem, który często jest popełniany przez początkujących analityków jest pomijanie w eksperymencie informacji o lokalizacji sklepu. Inaczej na zmianę cen reagują klienci zamożni, inaczej będą reagować klienci o ograniczonych zasobach, inaczej zareagują dzieci, inaczej zareagują dorośli. Dlatego sklepik szkolny ze słodyczami będzie cechował się inną elastycznością tych samych produktów niż sklep znajdujący się z dala od centrum miasta.

Scenariusze cenowe i symulacje



Mając zbudowane na danych kontekstowych modele popytu oraz określoną w drodze eksperymentów szacowaną elastyczność produktów, można przystąpić do projektowania scenariuszy cenowych – czyli zestawów założeń jak zmienimy ceny wybranych produktów lub kategorii – oraz przeprowadzenia symulacji ich skutków. Symulacja cenowa polega na komputerowym „przetestowaniu” różnych wariantów cen bez wprowadzania ich od razu w sklepach. Wykorzystuje się do tego historyczne dane sprzedażowe, modele popytu oraz zdefiniowane cele biznesowe i ograniczenia (np. docelowa marża, maksymalny dopuszczalny spadek wolumenu, pozycja cen względem konkurencji) jako dane wejściowe. Zaawansowane algorytmy (często wsparte sztuczną inteligencją) potrafią następnie zasymulować, jaki będzie popyt, przychód i marża dla każdego scenariusza cenowego. Istnieje tu analogia do testów A/B, jednak różnica polega na tym, że symulacja cen odbywa się w wirtualnym środowisku, podczas gdy testy cenowe A/B oznaczają rzeczywiste zmiany cen w wybranych sklepach lub kanałach sprzedaży. W praktyce symulacje często wykorzystują metody statystyczne takie jak:

- **Bootstrapping:** losowanie ze zwracaniem z historycznych danych w celu estymacji zmienności wyników,
- **Monte Carlo:** wielokrotne losowe próbkowanie wyników w celu wyznaczenia rozkładu prawdopodobieństwa dla zadanych parametrów.

Dzięki tym technikom można uwzględnić niepewność prognoz i naturalną zmienność popytu, np. zamiast pojedynczej prognozy sprzedaży dla danej ceny, otrzymujemy rozkład możliwych wyników wraz z oszacowaniem ryzyka (metoda *cross validation*). Zaawansowane platformy analityczne oferują tzw. sandboxy lub cyfrowe bliźniaki rynku, które odwzorowują

zachowanie sieci sklepów i klientów w odpowiedzi na zmiany cen. Pozwala to przetestować np. scenariusz podniesienia ceny wszystkich słodkich przekąsek o 5% i jednoczesnego obniżenia ceny chleba w sklepach osiedlowych, pozostawiając bez zmian w centrach handlowych. Można wtedy zobaczyć, jak takie decyzje wpłynęłyby na łączną sprzedaż, marżę oraz udziały rynkowe – zanim podejmie się to ryzyko w realnym świecie. Symulacje scenariuszowe pomagają wybrać najbardziej zrównoważoną i opłacalną strategię cenową do realizacji założonych celów (np. maksymalizacji zysku lub obrony udziału w rynku) w sposób proaktywny i poparty danymi. Co więcej, mogą one ujawnić mniej oczywiste zależności w portfelu produktów – np. symulując jednoczesne zmiany cen wielu artykułów można wykryć efekty kanibalizacji sprzedaży, gdy podniesienie ceny produktu A zwiększa sprzedaż produktu B lub odwrotnie oraz komplementarności, czyli wzajemnego napędzania się popytu. Takie informacje pozwalają lepiej skoordynować politykę cenową w całym asortymencie.

W obszarze chmurowym można wykorzystać wirtualny rynek w następujących modułach:

AWS Supply Chain & Digital Twins – AWS nie ma gotowego „retail pricing twin”, ale daje komponenty (AWS IoT TwinMaker, AWS Forecast, SageMaker) do budowania własnych sandboxów sprzedażowo-cenowych;

Microsoft Azure Digital Twins – platforma ogólna do budowy cyfrowych bliźniaków; w retailu używana np. do modelowania zachowań sklepów i łańcucha dostaw;

Google Cloud Platform (Vertex AI + BigQuery) – nie ma gotowego modułu „pricing sandbox”, ale można zbudować własne środowisko: dane w BigQuery, modele elastyczności w Vertex AI, a symulacje i optymalizacje w Pythonie (np. z Gurobi albo Pyomo).

Jeżeli nie chcemy korzystać z chmury, możemy zbudować taką symulację na własnym laptopie. Oto najważniejsze frameworki pythona, którymi można się posłużyć:

mesa – framework do symulacji agentowych (np. modelowanie zachowań klientów w reakcji na zmiany cen);

anylogic (komercyjny, ale z darmowym Personal Edition) – często stosowany w retailu do „market simulation” (hybryda agent-based + system dynamics);

pandapower/networkx – biblioteki do modelowania sieci i przepływów, można je adaptować do modelowania przepływu towarów i popytu.

Polityka cenowa a wyniki finansowe

Każda zmiana ceny od razu przekłada się na podstawowe wyniki finansowe sieci sklepów. Łączny przychód to iloczyn ceny i sprzedanego wolumenu, zaś marża brutto zależy od różnicy między ceną sprzedaży a kosztem produktu. Polityka cenowa jest więc ciągłym balansowaniem pomiędzy wolumenem sprzedaży a marżą jednostkową. Obniżając ceny można zwiększyć popyt (co podnosi obroty, ale zmniejsza marżę na sztuce), natomiast podnosząc ceny – poprawić marżę na produkcie, lecz ryzykuje się spadek wolumenu sprzedaży. Optymalna decyzja zależy od wcześniej omówionej elastyczności popytu: dla produktów o wysokiej elastyczności nawet niewielka podwyżka ceny może wywołać duży spadek

sprzedaży, potencjalnie obniżając łączny zysk; przy produktach nieelastycznych możliwe jest podniesienie ceny bez istotnej utraty wolumenu, co przekłada się na wyższy zysk. Analizy scenariuszowe pozwalają oszacować efekt netto takich zmian, np. czy wzrost ceny o 5% w danej kategorii spowoduje relatywnie mniejszy spadek wolumenu (a zatem wzrost marży łącznej), czy jednak łączny zysk finalnie spadnie. Często celem jest znalezienie punktu cenowego maksymalizującego zysk lub inny wybrany wskaźnik (np. przychód, udział rynkowy). Jest to typowe zadanie optymalizacyjne, które – mając model popytu – można rozwiązać analitycznie lub numerycznie. Przykładowo, dysponując równaniem popytu w funkcji ceny, da się obliczyć wprost cenę optymalną metodami rachunku różniczkowego; alternatywnie można przeprowadzić symulację komputerową, sprawdzając różne poziomy cen i wybierając ten, dla którego model przewiduje najwyższy zysk. W praktyce uwzględnia się przy tym liczne ograniczenia biznesowe, takie jak minimalna akceptowalna marża, docelowa pozycja cenowa względem konkurencji czy ograniczenia podażowe. Nowoczesne systemy do optymalizacji cen wykorzystują algorytmy z ograniczeniami (*constraint optimization*), które potrafią jednocześnie brać pod uwagę wiele takich celów i warunków – np. utrzymanie określonego poziomu marży, nieprzekraczanie o X% ceny głównego konkurenta, ograniczenie spadku wolumenu do Y% – i automatycznie znajdować rozwiązanie spełniające te kryteria. Złożoność powiązań bywa tak duża, że algorytmy sztucznej inteligencji mogą tu znacznie usprawnić proces decyzyjny: systemy AI uczą się na danych (np. estymują rzeczywistą elastyczność popytu na podstawie historii sprzedaży), a następnie proponują ceny maksymalizujące wybrany cel biznesowy przy danych ograniczeniach.

Błędne decyzje cenowe szybko odbijają się na wyniku finansowym – zbyt agresywne obniżki mogą nadmiernie zmniejszyć marżę, a zbyt wysokie ceny mogą ograniczyć obroty. Dlatego tak istotne jest testowanie decyzji *ex ante* (za pomocą opisanych symulacji) i wdrażanie spójnej, opartej na danych strategii cenowej, która równoważy cele sprzedażowe i marżowe.

Wpływ cen na percepcję klienta i markę

Polityka cenowa wpływa nie tylko na twarde wskaźniki finansowe – kształtuje też wizerunek cenowy firmy w oczach klientów. Wizerunek cenowy to ogólne postrzeganie poziomu cen i wartości oferowanej przez daną sieć sklepów, wykraczające poza obiektywne ceny na półkach. Klienci wyrabiają sobie opinię czy dana piekarnia jest „tania”, „przystępna”, czy „droga (premium)” na podstawie swoich doświadczeń zakupowych, obserwacji cen kluczowych produktów oraz przekazu marketingowego. Na percepcję tę wpływają m.in. jakość produktów, częstotliwość i głębokość promocji, ogólne pozycjonowanie marki na tle konkurencji oraz sposób komunikowania cen (np. czy sklep akcentuje w reklamach niskie ceny, czy raczej wyjątkowość jakości). Sieć piekarni może chcieć uchodzić za oferującą dobrą wartość za pieniądze – wtedy utrzymywanie atrakcyjnych cen na podstawowe produkty, takie jak chleb czy bułki, ma kluczowe znaczenie dla zbudowania zaufania. Rzeczywiście, pewne towary pierwszej potrzeby pełnią rolę tzw. produktów kluczowych dla postrzegania cen


(*Key Value Items*, KVI), które w największym stopniu wpływają na opinię klienta o cenach całego sklepu. Jeśli podstawowy bochenek chleba będzie znacząco droższy niż u konkurencji, wielu klientów może uznać całą sieć za drogą – nawet jeśli inne wyroby mają ceny zbliżone do rynkowych. Dlatego detaliści często identyfikują listę takich artykułów i świadomie utrzymują ich ceny na możliwie niskim poziomie, aby chronić pozytywny wizerunek cenowy sklepu. Z drugiej strony, budując wizerunek wyższej jakości, firma może komunikować wyjątkowość swoich wyrobów cukierniczych i utrzymywać nieco wyższe ceny – pod warunkiem, że klienci postrzegają te ceny jako uzasadnione wysoką jakością. Czyli produkty nazwijmy to prestiżowe mają istotnie większy współczynnik sztywności cenowej.

Promocje i eventy a indeks cenowy sklepu

Indeks cenowy to miernik porównujący średni poziom cen sklepu względem rynku lub wybranego konkurenta. Jest to użyteczne narzędzie wewnętrzne, ale nie oddaje całej złożoności percepcji cen przez konsumentów. Dwie sieci mogą mieć podobny indeks cen, zbliżone średnie ceny w koszyku produktów, a mimo to różnić się postrzeganiem, np. jeśli jedna z nich regularnie organizuje promocje i komunikuje okazje, robi eventy i rozmaite akcje promocyjne. Klienci mogą uważać taką piekarnię za bardziej korzystną cenowo. W rzeczywistości postrzeganie klientów wynika nie tylko z poziomu cen, ale także z ich kontekstu: skojarzeń jakości, obsługi, doświadczenia zakupowego, wystroju wnętrza oraz lokalizacji sklepu. Pozytywny wizerunek cenowy przynosi firmie istotne korzyści – konsumenci postrzegają ofertę jako dobrą wartość za pieniądze, chętniej odwiedzają sklepy i pozostają lojalni. Taki pozytywny wizerunek może nawet pozwolić firmie utrzymać nieco wyższe ceny od konkurencji, ponieważ klienci czują, że stoją za nimi lepsza jakość czy inne benefity. Z kolei negatywny wizerunek zniechęca do zakupów i może wymusić kosztowne promocje obniżające ceny w celu odzyskania klientów. W związku z tym decyzje cenowe muszą być podejmowane z uwzględnieniem ich wpływu na markę – nie tylko na bieżące wyniki, ale i na długofalowe postrzeganie firmy na rynku.

Narzędzia i metody analizy cenowej

W praktyce wdrażanie podejścia data science w obszarze polityki cenowej opiera się na zestawie narzędzi i metod analitycznych. Podstawą jest odpowiednia infrastruktura do gromadzenia i przetwarzania danych – najczęściej hurtownie danych i bazy SQL połączone z narzędziami Business Intelligence (BI) do raportowania (takimi jak Tableau czy Power BI) oraz środowiskami analitycznymi (np. Python z bibliotekami Pandas, scikit-learn, SciPy albo R z pakietami statystycznymi), z których korzystają analitycy. W tych środowiskach stosuje się szereg metod, m.in.:



- **Analizę statystyczną i ekonometryczną** – np. modele regresji do kwantyfikacji wpływu ceny na sprzedaż, modele szeregów czasowych do prognozowania trendów i sezonowości sprzedaży, czy testy statystyczne do oceny istotności obserwowanych zmian;
- **Uczenie maszynowe (*machine learning*)** – bardziej złożone algorytmy (jak lasy losowe, modele gradient boosting, sieci neuronowe) służą do prognozowania popytu, segmentacji sklepów według wzorców sprzedaży i wrażliwości cenowej lub wykrywania ukrytych zależności (np. grup produktowych o podobnej reakcji na zmiany cen). Modele ML mogą automatycznie uczyć się na danych transakcyjnych, identyfikując np. grupy sklepów o podobnym profilu klientów lub produkty kupowane razem;
- **Analizę elastyczności cenowej** – metody obliczania elastyczności popytu na podstawie danych (opisane wcześniej). W praktyce wykorzystuje się np. dopasowanie modelu log-liniowego popytu, gdzie współczynnik przy zmiennej cenowej stanowi miernik elastyczności, lub analizę regresji z danymi panelowymi (łączenie danych wielu sklepów i okresów) dla większej wiarygodności. Ważne jest też wizualizowanie wyników – np. krzywa popytu pokazująca, jak spada sprzedaż wraz ze wzrostem ceny – co ułatwia komunikację z decydentami biznesowymi;
- **Analizę scenariuszową (*what-if analysis*)** – narzędzia pozwalające zasymulować wyniki różnych decyzji cenowych. Często jest to zaimplementowane w arkuszach kalkulacyjnych lub aplikacjach BI jako interaktywne kokpity: użytkownik zmienia założenia (np. +10% do ceny produktu X, -5% do ceny produktu Y), a narzędzie od razu pokazuje przewidywany wpływ na przychód i marżę, bazując na wbudowanym modelu popytu. Bardziej zaawansowane rozwiązania, jak wspomniane wcześniej sandboxy, potrafią korzystać z modeli AI i rzeczywistych danych historycznych, by w specjalnym środowisku testowym imitować skutki planowanych zmian;
- **Optymalizację matematyczną** – wykorzystanie algorytmów optymalizacyjnych do wyznaczania najlepszych cen przy zadanych kryteriach. Mam na myśli metody badań operacyjnych do wyznaczania najlepszej decyzji przy spełnieniu zestawu ograniczeń. W praktyce to rodzina problemów typu programowanie liniowe. Może to przybrać formę rozwiązywania wprost zadania maksymalizacji zysku (np. za pomocą programowania liniowego lub nieliniowego, jeśli dysponujemy analityczną funkcją popytu) albo stosowania metod heurystycznych i przeszukiwania (np. algorytmy genetyczne, symulowane wyżarzanie) w przypadku złożonych problemów. W obszarze cen detalicznych coraz częściej wykorzystuje się do tego sztuczną inteligencję – wyspecjalizowane silniki cenowe łączą modele ML (szacujące popyt i elastyczność) z algorytmami optymalizującymi ceny pod kątem wielu ograniczeń jednocześnie. Przykładem może być silnik, który rekomenduje nowe ceny dziesiątek produktów tak, aby maksymalizować łączną marżę, a jednocześnie spełniać warunki typu „utrzymaj konkurencyjność cenową kluczowych produktów względem konkurenta A” i „nie pozwól, by przewidywany spadek wolumenu przekroczył 10%”;

- **Monitoring cen rynkowych** – specjalistyczne narzędzia do automatycznego śledzenia cen konkurencji (tzw. *pricing intelligence*). W e-commerce powszechnie używa się botów zbierających ceny z witryn konkurentów, ale również tradycyjne sieci sklepów korzystają z raportów cenowych i firm monitorujących ceny na rynku. Dzięki temu na bieżąco wiadomo, jak pozycjonuje się oferta względem innych graczy. Dane te zasilają modele (np. pozwalając uwzględnić reakcje konkurencji w analizie elastyczności) oraz służą menedżerom do bezpośrednich decyzji. Regularny monitoring ułatwia także planowanie promocji i identyfikację produktów, na których można bezpiecznie podnieść ceny. Przykładowo, system monitoringu może wykazać, że konkurencja podniosła ceny drożdżówek – co stwarza przestrzeń do analogicznej podwyżki. Z kolei jeśli nasz produkt jest najdroższy na rynku, dane te sygnalizują ryzyko spadku sprzedaży i mogą skłonić do korekty. Takie informacje pozwalają unikać sytuacji, w której firma nieświadomie oferuje towar zbyt drogo lub zbyt tanio – a ponadto umożliwiają testowanie różnych scenariuszy cenowych i dostosowywanie strategii w oparciu o reakcje rynku zamiast czystych założeń wewnętrznych;
- **Analizy koszykowe i indeksy cenowe** – techniki porównywania cen całych grup produktów. Sieć może wybrać reprezentatywny koszyk produktów (np. 10 najbardziej popularnych artykułów piekarskich) i regularnie porównywać jego łączny koszt w swoich sklepach oraz u konkurentów, obliczając indeks cenowy. Analiza koszykowa może też dotyczyć wewnętrznie różnych sklepów, np. porównywać poziom cen koszyka w sklepach osiedlowych vs. w centrach handlowych. Pozwala to ocenić spójność polityki cenowej i wykryć ewentualne nieuzasadnione rozbieżności. Indeksy cenowe stanowią również prosty komunikat dla kierownictwa (np. „nasze ceny są średnio 5% wyższe od głównego konkurenta” albo „utrzymujemy 95% poziomu cen dyskontu na produkty podstawowe”), co pomaga w strategicznym pozycjonowaniu. Warto jednak pamiętać, że suchy indeks nie oddaje w pełni percepcji klientów – dlatego powinien być uzupełniany badaniami opinii konsumentów i analizą udziałów rynkowych;
- **Testy A/B i eksperymenty cenowe** – w handlu tradycyjnym przeprowadzenie testu A/B (gdzie jedna grupa klientów doświadcza innej ceny niż druga) jest trudniejsze niż online, ale w pewnej skali możliwe. Sieć może np. w 10 losowo wybranych sklepach obniżyć cenę ciastka o 15%, pozostawiając pozostałe sklepy bez zmian, a następnie porównać sprzedaż i marżę między tymi grupami. Jeśli różnica jest istotna, stanowi to empiryczny dowód efektu zmiany ceny. Innym podejściem są eksperymenty czasowe – na zmianę wprowadza się nową cenę i wraca do starej, obserwując za każdym razem wpływ na sprzedaż. Takie eksperymenty, choć trudne logistycznie, dostarczają najbardziej wiarygodnych danych o zachowaniu klientów i mogą służyć do kalibracji modeli. W erze kanałów cyfrowych i programów lojalnościowych coraz łatwiej też implementować targetowane promocje (np. kupony rabatowe dla wybranych segmentów klientów) i uczyć się na ich podstawie, jak różne grupy reagują na zmiany cen.

Jak widać, arsenał narzędzi jest szeroki – od tradycyjnej analizy danych po algorytmy sztucznej inteligencji. Ważne jest jednak, aby zespół odpowiedzialny za politykę cenową rozumiał zarówno metody analityczne, jak i kontekst biznesowy. Tylko wtedy wyniki analiz przekładają się na trafne decyzje cenowe zgodne z celami firmy.

System rekomendacji w e-commerce a system optymalizacji cen

Oba te obszary naturalnie się uzupełniają. Rekomendacje odpowiadają na pytanie co pokazać klientowi, a optymalizacja cenowa odpowiada na pytanie po ile to zaoferować. Połączenie obu komponentów pozwala zwiększać przychody i marżę, jednocześnie poprawiając doświadczenie użytkownika.

Rekomendacje oparte na danych transakcyjnych, wyszukiwaniach czy zachowaniach klienta w witrynie (modele Collaborative Filtering, Factorization Machines, DeepFM) generują dynamiczne listy produktów najbardziej prawdopodobnych do zakupu. Jednak skuteczność tych sugestii zależy także od poziomu cen. Nawet najlepiej dopasowany produkt może pozostać w koszyku porzuconym, jeśli jego cena jest odbierana jako nieatrakcyjna. W tym miejscu wchodzi system optymalizacji ceny, oparty na estymacji elastyczności popytu i algorytmach programowania liniowego lub mieszańsko-całkowitoliczbowego.

Z jednej strony moduł rekomendacyjny dostarcza systemowi pricingowemu informacji o preferencjach klienta i koszykach kontekstowych. To umożliwia bardziej granularną optymalizację: cena tego samego produktu może być inna w zależności od segmentu czy historii zachowań klienta. Z drugiej strony wyniki optymalizacji cenowej – np. wyznaczone poziomy cen czy granice promocji – stają się dodatkowym wejściem do algorytmu rekomendacji, tak, aby system nie promował produktów o niskiej marży lub poza strategią wizerunkową.

Technicznie integracja odbywa się w warstwie danych i modeli. Dane o elastyczności cenowej, indeksach cenowych i prognozach marży można przechowywać w hurtowni (BigQuery, Snowflake), a następnie w czasie rzeczywistym przysyłać do silnika rekomendacyjnego. Modele uczenia maszynowego mogą być rozszerzone o cechy cenowe (*price features*), takie jak aktualna cena, rabat czy pozycja względem konkurencji. Systemy optymalizacji (Pyomo, Gurobi, OR-Tools) generują rekomendowane poziomy cen, które są używane jako stałe w modelu rekomendacyjnym, np. „pokazuj produkty z listy Top-10, ale tylko takie, które spełniają kryterium marży i indeksu cenowego”.

Efekt synergii jest to, że klient dostaje spersonalizowaną ofertę w atrakcyjnej cenie, a firma kontroluje zarówno konwersję, jak i rentowność. To połączenie rekomendacji z optymalizacją cenową staje się podstawą nowoczesnych systemów e-commerce, gdzie decyzja o ekspozycji i decyzja o cenie są rozwiązywane jednocześnie, w ramach jednego procesu data-driven.

Wojciech Moszczyński

Wojciech Moszczyński – absolwent Katedry Ekonometrii i Statystyki Uniwersytetu Mikołaja Kopernika w Toruniu; specjalista z zakresu ekonometrii, finansów, data science oraz rachunkowości zarządczej. Specjalizuje się w optymalizacji procesów produkcyjnych i logistycznych. Prowadzi badania w obszarze rozwoju i zastosowania sztucznej inteligencji. Od lat zaangażowany w popularyzację machine learning oraz data science w środowiskach biznesowych.