

Jak wspomagać handlowca sztuczną inteligencją?



Szybki system rekomendacji dla obsługi call center

Handlowiec, który klienta jeszcze nie zna

Wyobraźmy sobie biuro sprzedające maszyny produkcyjne, np. piece, linie pakujące, małe maszyny piekarskie. Biuro działa jak klasyczne call center: telefon dzwoni, konsultant podnosi słuchawkę, po drugiej stronie ktoś nowy, nowy klient. Zero historii zakupów, zero relacji. To tak zwany *cold service* – brak informacji, brak wspomagania dla handlowca jak z klientem rozmawiać.

Po kilku sekundach rozmowy zaczyna się typowy taniec: klient coś mówi, o coś pyta, trochę się zastanawia, trochę marudzi. Jeden klient jest niecierpliwy i chce mieć decyzję „na już”, drugi wchodzi w każdy szczegół techniczny. Handlowiec intuicyjnie próbuje się dostosować, ale robi to „na czuja”, bo nie zna ani historii, ani charakteru rozmówcy. Poza tym handlowiec sam jest obciążony swoją osobowością może nie umieć się dostosowywać w ułamku sekundy, wykrzyć jaki to typ klienta, może być niezmotywowany, zmęczony, przydałoby się wsparcie.

Jakie wsparcie?

Pomysł jest prosty: nagrywamy transkrypcję rozmowy i po kilku zdaniach model językowy wyciąga z niej psychologiczny profil decyzyjny klienta – nie pełną osobowość, tylko to, co ma znaczenie dla procesu zakupu. Na tej podstawie system podpowiada handlowcowi, jak prowadzić rozmowę: o czym mówić dużo, o czym mało, a czego lepiej nie poruszać.

Dzięki wspomaganiu sztuczną inteligencją klient ma poczucie „chemii” – rozmowa idzie w tempie i języku, który mu pasuje, a handlowiec nie musi zgadywać jak rozmawiać, bo dostaje wyraźne wytyczne na ekranie. To jest nowy typ sprzedawcy: handlowiec wspomagany systemami sztucznej inteligencji, który w czasie rzeczywistym dostaje dopasowane wskazówki.

Żeby taki system działał, potrzebujemy dwóch rzeczy:

1. sensownego zestawu wymiarów psychologii decyzyjnej klienta,



2. bardzo prostych, wręcz graficznych KPI dla handlowca – pracownik nie będzie podczas rozmowy wczytywał się w instrukcje, musi dostać szybką graficzną informację jak rozmawiać.

Pięć wymiarów, które naprawdę pomagają w sprzedaży

W literaturze jest mnóstwo teorii osobowości i stylów decyzji. W call center sprzedającym maszyny potrzeba czegoś mniej akademickiego, a bardziej „do użycia tu i teraz”. Proponuję pięć wymiarów.



Pierwszy wymiar to nastawienie na zysk vs nastawienie na bezpieczeństwo (Promotion vs Prevention)

- Klient w trybie nastawienie na zysk (promotion) mówi rzeczy w stylu: *Chciałbym coś mocniejszego, fajnie jakby był bogatszy pakiet; Interesuje mnie nowszy model, coś nowoczesnego;*

- Klient w trybie nastawienie na bezpieczeństwo (prevention): *Najważniejsze, żeby się nie psuło; Chcę mieć pewność, że rata mnie nie zaskoczy.*

Dla handlowca to jest prosta mapa:

- promotion → mów o rozwoju, wydajności, nowych możliwościach,

- prevention → mów o stabilności, gwarancjach, niskim ryzyku.

Oczywiście człowiek nie jest tak szybki i zmotywowany, aby w lot łapał nastawienie klienta. Robi to za niego maszyna. Model językowy może z transkrypcji wyciągnąć prosty wskaźnik: klient raczej promotion, raczej prevention, czy gdzieś pośrodku.

Drugi wymiar to styl szukania rozwiązania (Maximizer vs Satisficer)

- Maximizer: zadaje dużo pytań, porównuje, wraca do wcześniejszych opcji: *A jakie są jeszcze inne wersje?; A ile to wychodzi w pięcioletnim okresie?; A w porównaniu do tamtego modelu?*

Boi się podjąć decyzję zbyt szybko, żeby potem nie żałować.

- Satisficer: szuka rozwiązania „wystarczająco dobrego”, szybko akceptuje rozsądną propozycję: *Jeśli Pan mówi, że to dobra konfiguracja, to bierzmy tę. Nie musimy dalej szukać.*

W call center:

- dla Maximizerów przydatne są krótkie, ale porządne porównania, liczby, TCO,

- dla Satisficerów lepiej zadziała jedna, dwie dobrze opisane opcje, bez szerokiej listy.

Trzeci wymiar to dwa wątki: wrażliwość na cenę i awersja do ryzyka (Price sensitivity i risk aversion)

- Wrażliwość cenowa (price sensitivity): *A jaki rabat uda się jeszcze uzyskać?; To jednak za wysoka rata, musimy zejść niżej*

- Awersja do ryzyka (risk aversion): *Bo ja się boję tych nowych napędów/ zmiennej stopy/używanych maszyn; Najlepiej stała rata, długi okres gwarancji.*

Model sztucznej inteligencji może od razu zaznaczyć: klient ma **wysoką wrażliwość cenową** (będzie twardo negocjował), albo **wysoką awersję do ryzyka** (nie wciśniesz mu skomplikowanego finansowania z niepewnym kosztem końcowym). Z tego wprost wynikają wskazówki:

- wysoka price sensitivity → wyraźne rabaty, porównania kosztów, argument „to się opłaca”,

- wysoka risk aversion → stałe raty, długie gwarancje, zero niespodzianek.



Czwarty wymiar to klasyczne style podejmowania decyzji przez konsumenta

W praktyce sprzedaży maszyn nie potrzebujemy całej teorii, wystarczy kilka etykiet:

- Quality-conscious/perfectionist – *ma być porządne, nie najtańsze*

- Price-value conscious – *ma się opłacać, najlepszy stosunek cena/jakość*

- Brand loyal – *biorę tę markę, bo zawsze tak robię*

- Impulsive/habitual – *działa szybko, czasem schematycznie (jak zawsze).*

Dla handlowca:

- perfectionist → warto wejść głębiej w parametry, jakość wykonania, certyfikaty,

- price-value → pokazać konkretne równanie: „tyle kosztuje, tyle oszczędza”,

- brand loyal → nie rozbijaj się ofertą konkurenta, tylko pokaż nowy model ulubionej marki.

Nie zawsze da się to odczytać z jednej rozmowy, ale w wielu przypadkach klient sam daje sygnały (*ja od lat mam tylko X*).

Piąty wymiar to sposób mówienia, a nie „co” klient wybiera

Style komunikacji: directness i detail orientation

Direct vs indirect: czy klient mówi: *Chcę maszynę do 3 tys. miesięcznie, proszę konkrety*, czy raczej opowiada długo o kontekście, pracownikach, historii firmy.

Detail-oriented vs big-picture: czy pyta o szczegółowe parametry (moc silnika, grubość blachy, typ łożysk), czy raczej: *żeby było wygodnie, żebyśmy się nie martwili.*

To pozwala dopasować długość i styl wypowiedzi konsultanta: krótkie, konkretne zdania dla bezpośrednich, bardziej opisowo dla klientów, którzy potrzebują „opowieści”.

Co da się wyciągnąć z krótkiej rozmowy?

Nie trzeba długich ankiet. Już w pierwszych minutach rozmowy widzimy mocne sygnały:

- Promotion vs prevention – praktycznie od pierwszego zdania (*chcę większą wydajność vs najważniejsze, żeby się nie psuło*)
- Maximizer vs satisficer – po kilku pytaniach: albo klient kopie głęboko, albo mówi: *wystarczy*
- Price sensitivity/risk aversion – w każdym pytaniu o rabat, w każdej uwadze o ryzyku.

Model językowy potrafi z transkrypcji zebrać te sygnały i wygenerować strukturalny opis: klient bardziej promotion, wysoka awersja do ryzyka, średnia wrażliwość cenowa, raczej maximizer, dość bezpośredni.

Trudniejsze są:

- głębokie style decyzyjne (perfectionist vs brand-loyal) – czasem w ogóle nie wychodzą w pierwszej rozmowie,
- abstrakcyjne wartości (np. podejście do pracy i życia) – tego tu nie potrzebujemy.

Dlatego warto trzymać się mocnych wymiarów, które da się odczytać szybko: promotion/prevention, maximizer/satisficer, price sensitivity, risk aversion, directness, detail-orientation. Ogólnie mówiąc wszyscy znają takie podejście przynajmniej od 150 lat, ale nikt go nie stosował, ponieważ ludzie nie są maszynami, nie są w stanie ogarnąć kilku wymiarów jednocześnie dalej analizując przekaz i w tym samym momencie rozmawiać. To temat dla sztucznej inteligencji.

Dlaczego pragmatyczne zimne instrukcje dla handlowca są bezużyteczne

Założmy, że model policzył, iż klient ma:

- Maximizer 70%
- Satisficer 30%

Brzmi mądrze, ale co z tym ma zrobić handlowiec w środku rozmowy? Ma mówić 70% czasu jak do Maximizerów, a 30% jak do Satisficerów? To jest informacja nieczytelna operacyjnie. Dobra do publikacji w artykule, fatalna do użycia na słuchawce.

Handlowiec potrzebuje prostych sygnałów, najlepiej takich, które widać wręcz graficznie na ekranie: czerwone, żółte, zielone; ikona „mów dużo”, ikona „nie dotykaj”. Dla niego ważne jest:

- czy ma dać klientowi dwie oferty, czy pięć,
- czy ma dużo mówić o finansowaniu, czy tylko zarysować,
- czy ma w ogóle wchodzić w porównania z konkurencją, czy to klienta zniechęca.

Dlatego sama informacja liczbowo-procentowa jest za „gęsta”. Trzeba ją zredukować do prostych KPI, które są zgodne ze zdrowym rozsądkiem.



KPI oparte na zdrowym rozsądku: „MÓW_DUŻO”, „MÓW_MAŁO”, „NIE_MÓW”

Zamiast pokazywać handlowcowi cztery wykresy radarowe i tabelę procentów, lepiej zadać kilka bardzo prostych pytań, np.:

1. Jak mówić o szczegółach technicznych?
2. Jak mówić o finansowaniu?
3. Jak mówić o awaryjności/niezawodności?
4. Jak mówić o przewadze konkurencyjnej?

Na każde pytanie odpowiedź może być zredukowana do:

- **MÓW_DUŻO** – temat kluczowy, rozwijaj, wracaj do niego,
- **MÓW_MAŁO** – zaznacz, ale nie rozgaduj się,
- **NIE_MÓW** – lepiej ten wątek omijać, klient go nie chce słuchać.

To można wręcz narysować: cztery ikonki z kolorami, np. zielony pełny, żółty cienki pasek, czerwony przekreślony. System może w tle korzystać z całej psychologii, ale do handlowca wypuszcza tylko prostą instrukcję.


Jak w 5 minut uruchomić model suflera?

Oto adres pliku, w który znajdują się najważniejsze rzeczy potrzebne do uruchomienia modelu sztucznej inteligencji.

W pierwszym kroku należy wejść na któryś z Playgroundów. To tak zwane place zabaw gdzie można przetestować wybrane modele sztucznej inteligencji.

Przykładowe adresy:

<https://platform.openai.com/chat/edit?models=gpt-4.1>
<https://app.fireworks.ai/playground>



Na górze zwykle jest lista modeli do wyboru. Gdzieś na dole należy wkleić gotowy prompt, czyli protokół, który instruuję model co ma zrobić. Taki prompt dokładnie dla naszego call center znajduje się w tym pliku: <https://github.com/ff-wm/PPIC/blob/main/A2.ipynb>.

Teraz możemy postępować zgodnie z instrukcją zawartą w tym pliku.

Plik ten służy do testowania odpowiedzi różnych modeli LLM na wybrane dialogi klientów. Plik zawiera trzy dialogi klientów: „Dialog dramatyczny”, „Dialog neutralny”, „Dialog osoba wrażliwej”. W podanych witrynach jest możliwość uruchomienia protokołu API, czyli połączenia stanowiska call center z modelem sztucznej inteligencji i korzystanie z bezpośrednich wskazówek jak rozmawiać z klientem.

Zakończenie: nowy typ handlowca

Ten system nie jest wyrocznią. Krótka rozmowa oznacza:

- mniejszą pewność co do klasyfikacji,
- ryzyko, że model dopowie sobie rzeczy, których klient nie powiedział.

Warto dodawać wewnętrzny wskaźnik zaufania (np. wysoki/średni/niski) i w UI pokazywać to w prosty sposób (np. intensywność koloru). Lepiej pytać model o konkretne zachowania w rozmowie (*jak klient reagował na*

pytanie	zalecany poziom
Jak mówić o szczegółach technicznych?	NIE_MÓW
Jak mówić o finansowaniu?	MÓW_DUŻO
Jak mówić o awaryjności / niezawodności?	MÓW_DUŻO
Jak mówić o przewadze konkurencyjnej?	NIE_MÓW

temat ceny?), niż o ogólny „charakter”. Warto łączyć wynik z twardymi danymi: wielkość firmy, typ działalności, dotychczasowe zakupy.

Mimo to, nawet z tymi ograniczeniami, już sam podział na proste KPI „MÓW_DUŻO/MÓW_MAŁO/NIE_MÓW” jest ogromnym krokiem naprzód w porównaniu z sytuacją, w której handlowiec wpada na rozmowę kompletnie „na ślepo”. Model językowy nie zastąpi konsultanta, ale może go ustawić na właściwy tor w pierwszych minutach rozmowy. Zamiast abstrakcyjnych procentów „Maximizer 70%”, handlowiec dostaje cztery proste komunikaty: nie dotykaj technikaliów, mów dużo o finansowaniu, mocno akcentuj niezawodność, nie rób wykładu o przewadze konkurencyjnej.

To jest właśnie nowy rodzaj handlowca wspomaganego AI: człowiek prowadzi rozmowę, ale system na bieżąco podpowiada, jakie wątki rozwijać, a jakie omijać. Klient czuje, że ktoś go „rozumie”, rozmowa płynie, a biuro call center przestaje być loterią, w której wszystko zależy od humoru konsultanta i czystej intuicji.

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.