

Dobór pary handlowiec-klient w call center dla branży piekarsko-cukierniczej



Artykuł opisuje metodę analizy rozmów telefonicznych w firmie, która zaopatruje przemysł spożywczy, w tym piekarnie i cukiernie, w części zamienne do maszyn, podzespoły, elementy wymienne, materiały eksploatacyjne oraz wybrane półfabrykaty. W takiej działalności część klientów jest stała i składa zamówienia automatycznie, np. przez integracje systemowe, natomiast duża grupa klientów zamawia przez telefon, pyta o parametry, negocjuje cenę, ustala terminy i warunki dostawy.



W rozmowach często pojawiają się pozycje drogie, takie jak moduły maszyn, napędy, sterowania, elementy precyzyjne, ale także tanie elementy zużywalne, które w skali miesiąca generują duży obrót.

Najważniejszy cel opisanej tutaj analizy jest praktyczny i biznesowy, a jednocześnie bardzo konkretny. Klient ma zostać szybko rozpoznany na podstawie rozmowy, a następnie skierowany do takiego

handlowca, który najlepiej pasuje do jego stylu rozmowy i sposobu podejmowania decyzji. Dobrze dobrana para klient – handlowiec podnosi prawdopodobieństwo sprzedaży, natomiast źle dobrana – potrafi przerwać transakcję nawet wtedy, gdy klient realnie potrzebuje części i ma budżet. Ponieważ sprzedaż telefoniczna jest realizowana w call center, rozmowy są nagrywane, następnie przepisywane na tekst, a potem analizowane w sposób powtarzalny i możliwie stabilny w czasie.

Etap pierwszy – nagranie rozmowy i transkrypcja

Rozmowy telefoniczne są nagrywane przez system call center, a skala jest masowa, ponieważ miesięcznie mogą to być tysiące połączeń. Klient na starcie jest identyfikowany głównie numerem telefonu, co pozwala łączyć rozmowy w historię kontaktu i zestawiać je z danymi sprzedażowymi oraz danymi z systemów firmy.

Po zakończeniu rozmowy wykonuje się transkrypcję, czyli zapis mowy w formie tekstu, stosując model Whisper -1 z OpenAI. Następnie trzeba rozdzielić wypowiedzi na dwie role, czyli ustalić, które fragmenty należą do klienta, a które do handlowca. W praktyce wiele modeli

nie robi tego pewnie, bo głosy się nakładają, ludzie przerywają sobie, a czasem rozmowa jest szybka i chaotyczna. Dlatego w pipeline pojawia się dodatkowy model językowy, w tym podejściu jest to model o1 firmy OpenAI, który czyta treść i przypisuje wypowiedzi do ról na podstawie kontekstu rozmowy. Ten krok jest krytyczny, ponieważ dalsza analiza musi mieć pewność, kto mówi daną rzecz, inaczej wnioski będą pomieszane i nieużyteczne.

Wynik etapu pierwszego jest prosty w formie, bo to jest tekst rozmowy rozdzielony na role i zapisany w bazie jako tabela, najczęściej jako DataFrame, często w pliku CSV, aby można było łatwo liczyć cechy i łączyć wyniki z innymi danymi.

Etap drugi – opis cech klienta i handlowca

Na drugim etapie transkrypcja z rozdzielonymi rolami jest przekazywana do analizy, w której model językowy wylicza cechy dla klienta i osobno dla handlowca. Wykorzystuje się dwie duże metodologie osobowości, czyli OCEAN, znane jako Big Five, oraz HEXACO, która rozszerza opis o dodatkowy wymiar. Każda cecha jest oceniana na skali 0-100, gdzie 0 oznacza brak nasilenia danej cechy, a 100 – maksymalne nasilenie, przy czym w praktyce większość wyników mieści się w średnich zakresach, a nie na skrajach.

Bardzo ważne jest, aby cechy były zapisane inaczej w osobnych kolumnach, ponieważ nazwy cech z OCEAN i HEXACO potrafią brzmieć podobnie, ale nie są w pełni tożsame między metodologiami, więc późniejsze modele muszą widzieć pełną strukturę danych. Do tego dochodzi analiza metod wpływu Cialdiniego, gdzie każda metoda jest kodowana w sposób binarny, czyli jako informacja, czy dana metoda pojawiła się w rozmowie, czy nie pojawiła się w rozmowie. Taką analizę prowadzi się dla klienta i dla handlowca, ponieważ w sprzedaży telefonicznej wpływ działa w obie strony, a styl komunikacji jest częścią wyniku.

Równolegle liczone są heurystyki, czyli proste cechy treściowe i behawioralne, które da się wyczytać z rozmowy bez wchodzenia w teorię osobowości. Są to np. sygnały, czy klient ma już wybraną część albo konkretną maszynę, czy jest zdecydowany, czy mocno negocjuje cenę, czy pyta o kwestie techniczne i kompatybilność, czy pyta o formalności, gwarancję, prawo i podatki, czy naciska na termin, czy woli spokojne ustalenia, oraz czy wykazuje nastawienie ostrożne albo ryzykowne. Te same obserwacje można prowadzić po stronie handlowca, bo jeden handlowiec prowadzi rozmowę proceduralnie, drugi relacyjnie, trzeci technicznie, a czwarty próbuje szybko domykać sprzedaż.

Wynik etapu drugiego to zestaw cech opisujących rozmowę i obie strony, zapisany w danych w sposób liczbowy tak, aby dało się go wykorzystać do dalszego podziału, porównań i testów.

To po prostu poziomy cech, które zostały wykryte przez kolejny w tym projekcie trzeci model sztucznej inteligencji.

Etap trzeci – klasyfikacja do grup i macierz sprzedaży

W trzecim etapie można zastosować model językowy, który na podstawie zebranych cech przypisuje klientów i handlowców do kilku grup opisowych, które w praktyce nazywa się archetypami. Dla handlowców w tej pracy przyjmuje się cztery typy, czyli handlowca narzucającego własną wolę, handlowca będącego strażnikiem procedur, handlowca relacyjnego i przyjacielskiego oraz handlowca spontanicznego, który działa bardziej wizjonersko i elastycznie. Po stronie klientów można zbudować analogiczny podział, co daje prostą strukturę do analizy.

Następnie buduje się macierz prawdopodobieństwa sprzedaży, w której zestawia się typ klienta z typem handlowca, a w komórkach pojawia się odsetek udanych transakcji. Informacja o sukcesie sprzedaży pochodzi z systemów firmy, takich jak CRM i księgowość, gdzie widać czy zamówienie zostało złożone i doprowadzone do końca. Taka macierz ma wartość praktyczną, ponieważ łatwo pokazuje, że pewne zestawienia osób, par klient – handlowiec pracują lepiej, a inne gorzej, co wprost wspiera decyzje o kierowaniu połączeń do odpowiednich handlowców.

Ograniczenie podejścia archetypowego i problem stabilności

W praktyce ten etap ma poważne ograniczenie, ponieważ archetypy tworzone przez model językowy nie są pełną klasteryzacją statystyczną, a część realnych cech



ludzi jest ukryta, mieszana i zależna od sytuacji. W badaniach widać też problem stabilności w czasie, ponieważ prawdopodobieństwa sprzedaży dla tych samych par potrafią zmieniać się tydzień po tygodniu. Zdarza się, że przez kilka tygodni dana para wygląda bardzo dobrze, a później efekt słabnie albo znika, co oznacza, że na takim podziale trudno budować komercyjny system routingu, który ma działać stale i przewidywalnie.

Z tego wynika ważny wniosek, że potrzebna jest metoda bardziej stabilna, a także taka, która lepiej wykorzysta większą liczbę cech i nie będzie opierała się tylko na czterech sztywnych grupach.

Etap czwarty – klasteryzacja statystyczna z redukcją wymiaru

W etapie czwartym przechodzi się do klasteryzacji klasycznej, ale najpierw trzeba poradzić sobie z dużą liczbą cech, bo w danych można mieć kilkadziesiąt zmiennych naraz. Stosuje się więc analizę głównych składowych, czyli PCA, która kompresuje informację do kilku wymiarów, zachowując możliwie dużo treści i porządkując dane w przestrzeni.

Po tej redukcji można zastosować metodę k średnich, czyli k-means, aby znaleźć naturalne grupy w danych.

Liczbę klastrow dobiera się metodą łokcia, czyli przez analizę wykresu, na którym widać, w którym miejscu dalsze zwiększanie liczby klastrow przestaje dawać duży zysk jakości. To daje rozsądny punkt startowy do budowy klastrow klientów i klastrow handlowców.

Etap piąty – nowa macierz sprzedaży oraz warianty eksperymentu

Gdy klienci i handlowcy mają przypisane klastry, tworzy się ponownie macierz prawdopodobieństwa sprzedaży, ale tym razem opartą na klastrach, a nie na archetypach opisowych. Założenie jest takie, że ten układ powinien być bardziej stabilny, bo wynika z danych, a nie z narzuconych etykiet.

Bardzo ważne jest też projektowanie wariantów eksperymentu, ponieważ inne zestawy cech mogą tworzyć inne skupiska i inne klastry. W praktyce warto testować różne kombinacje, na przykład same heurystyki z HEXACO, albo OCEAN z metodami Cialdiniego, albo pełen zestaw łączony, a także rozważyć cechy ilościowe wynikające z rozmowy, takie jak długość rozmowy, liczba słów oraz proporcja mówienia klienta i handlowca. Takie zmienne bywają zaskakująco informacyjne, zwłaszcza w rozmowach negocjacyjnych, gdzie sposób prowadzenia rozmowy bywa równie ważny jak temat.



Etap szósty – testy stabilności i wiarygodności

Ostatni etap to testy, które mają odpowiedzieć na pytanie czy klasteryzacja faktycznie stabilizuje wyniki sprzedażowe. W praktyce sprawdza się czy prawdopodobieństwa sprzedaży dla par klaster – klient/klaster – handlowiec są powtarzalne w kolejnych tygodniach, a także czy rozrzut tych prawdopodobieństw jest mały. Jeśli wyniki mocno skaczą, a odchylenie standardowe jest duże, to system kierowania klientów będzie ryzykowny i mało wiarygodny. Jeśli natomiast rozrzut jest mały i zależności są powtarzalne, wtedy można mówić o podstawie do wdrożenia.

Podsumowanie i zakończenie

W branży piekarsko-cukierniczej oraz szerzej w zaopatrzeniu przemysłu spożywczego rozmowy telefoniczne dotyczą często drogich urządzeń i kosztownych elementów, a także dużych zamówień na materiały eksploatacyjne, więc jakość rozmowy ma bezpośredni wpływ na wynik. Dlatego analiza rozmów w call center, oparta na nagraniach, transkrypcjach i policzonych cechach, jest sposobem na to, aby szybko rozpoznać klienta i kierować go do najlepiej dopasowanego

handlowca. Kluczowym warunkiem powodzenia jest stabilna metoda klasyfikacji, ponieważ routing, czyli przypisywanie odpowiednich handlowców do odpowiednich klientów, ma działać stabilnie bez niepotrzebnego braku przewidywalności.

Podejście archetypowe jest dobrym krokiem do pokazania kierunku i do rozmowy z biznesem, ale badania wskazują, że może być niestabilne w czasie, więc naturalnym ruchem jest przejście do klasteryzacji statystycznej z redukcją wymiaru oraz testami stabilności. W praktyce to właśnie stabilność, mierzona na tygodniach i na dużej liczbie rozmów, decyduje o tym, czy system da się wdrożyć jako narzędzie, które realnie zwiększa prawdopodobieństwo sprzedaży przez lepszy dobór pary klient handlowiec.

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.