

## **Jak generować trafne prognozy dla produktów bez długiej historii sprzedaży?**





W branży retail **wprowadzanie nowych produktów** na rynek i otwieranie nowych kanałów bądź punktów sprzedaży jest niemalże codziennością. To jednak **duże wyzwanie w kontekście prognozowania popytu i optymalnego zaopatrzenia nowego punktu bądź kanału.**

Jak zatem korzystać z siły sztucznej inteligencji i machine learningu do prognozowania popytu i sprzedaży w przypadku braku danych historycznych?

Rozpatrując metody analityczne, można wyróżnić **trzy grupy algorytmów**, które wykorzystuje się do prognozowania sprzedaży: pierwsza z nich oparta jest stricte na **machine learningu**. Wymaga jednak całego zakresu danych historycznych: dotyczących ceny, pogody, akcji marketingowych, etc., by dokonać trafnych obliczeń i generować jakościowe prognozy.

Druga z nich to **szereg czasowy**, który pracuje głównie na danych sprzedażowych, a ich historia nie musi być tak obszerna jak przy machine learningu. Trzecia grupa to „**naive algorithms**”. Przykładem może być średnia ruchoma. W tym przypadku na podstawie jednego dnia sprzedażowego, jesteśmy w stanie wygenerować prognozy na przyszłość, traktując uśrednione wyniki jako wyznacznik zakładanej sprzedaży.



Jako że trudno jest prognozować sprzedaż dla nowego kanału, sklepu czy produktu, warto podejść do generowania prognoz, wykorzystując po kolei wszystkie trzy kroki.

**01** Zaczynamy od „naive methods”. Korzystając z tego typu metod, jak średnia ruchoma, jesteśmy w stanie reagować na sytuację i zapotrzebowanie od razu po wyjściu nowości na rynek. Posiłkujemy się przy tym wiedzą i doświadczeniem pracowników, którzy wspierają proces prognozowania danymi i informacjami. W tym kroku jakość prognoz nie będzie idealna i traktujemy ją jako sugestię, nie zaś pewnik.

**02** Następnym krokiem jest wdrożenie szeregu czasowego. To metoda, która na podstawie danych sprzedażowych, zbieranych od wprowadzenia nowości na rynek, jest w stanie zidentyfikować i wychwycić trendy, zależności czy sezonowość. To zaś ważne czynniki z punktu widzenia prognozowania sprzedaży. Jakość i trafność są znacznie wyższe niż przy metodach naiwnych, a zaangażowanie pracowników w proces prognozowania mniejsze. W tym miejscu większość obowiązków przejmuje już sztuczna inteligencja.

**03** Ostatnim krokiem jest przejście w stronę algorytmów opartych o **machine learning**. Jakość takich prognoz będzie zadowalająca bez potrzeby zaangażowania dedykowanych pracowników. Wcześniej prowadzone procesy prognozujące są fundamentem do uczenia modeli machine learningowych. Tutaj, już w pełni automatycznie, z wykorzystaniem modelu, tworzone prognozy w określonych horyzontach czasowych, a także zapotrzebowania sklepowe i polecenia komisjonowania.

Czym bardziej zaawansowana i wyrafinowana charakterystyka sprzedaży, tym więcej szczegółowych i historycznych danych potrzebujemy. Jednak – przy pierwszych dniach wprowadzenia produktu do sprzedaży, **warto korzystać z naiwnych metod i ludzkiego wsparcia**. Nie oznacza to, że prognozy będą bezcelowe – stanowią nie tylko punkt odniesienia do tworzenia zapotrzebowań sklepowych i zatowarowania poszczególnych punktów. Są także **fundamentem dla uczenia modeli machine learningowych**, które zasilane danymi sprzedażowymi będą podstawą do działania w pełni zautomatyzowanych prognoz w oparciu o AI i ML.



W strategii prognozowania sprzedaży nowych produktów oferujemy dwie możliwości: ścieżkę opartą o **ekspertyzę użytkowników** i ścieżkę wykorzystującą zaawansowane **techniki uczenia maszynowego**.

W ścieżce eksperckiej prognozowania dla nowych produktów, to użytkownik systemu odgrywa kluczową rolę w **definiowaniu produktów referencyjnych**, na których oparte będą prognozy sprzedaży dla nowych produktów. Proces ten zaczyna się od zidentyfikowania przez użytkownika produktów referencyjnych, które zostały sprzedane w przeszłości i mogą być uznane za powiązane z nowym produktem. Użytkownik ma możliwość definiowania **kilku produktów referencyjnych** dla **jednego nowego SKU**, określając także wagę każdego z nich w procesie prognozowania.

Ponadto, istnieje opcja definiowania referencji na poziomie kategorii produktowej zamiast konkretnego produktu. Definiowanie referencji może być przeprowadzone **za pomocą interfejsu Occubee** lub poprzez **załadowanie pliku .csv** z odpowiednią strukturą danych. Dzięki ścieżce eksperckiej, użytkownicy mają kontrolę nad wyborem produktów referencyjnych i ich wagą.

W ścieżce opartej na **uczeniu maszynowym** Occubee wykorzystuje zaawansowane algorytmy do prognozowania sprzedaży nowych produktów na podstawie **cech (atrybutów)** produktów oraz ich przynależności do kategorii produktowej. Ten proces jest szczególnie użyteczny, gdy nowy produkt należy do kategorii produktowej już obecnej w portfolio firmy, oraz gdy istnieje zbiór cech, które występowały wcześniej w produktach posiadających historię sprzedaży. Modele uczenia maszynowego analizują te cechy oraz ich wzorce występujące w produktach z przeszłości, aby przewidzieć **potencjalną sprzedaż nowego produktu**.

Poprzez identyfikację trendów i wzorców na poziomie cech produktów, modele mogą dokładnie prognozować, jak nowy produkt może odnieść się do wcześniejszych sukcesów sprzedażowych w danej kategorii. Korzystając z tej ścieżki, Occubee umożliwia automatyczne i precyzyjne prognozowanie sprzedaży nowych produktów, wykorzystując mnogość danych związanych z cechami produktów i ich kategorią.



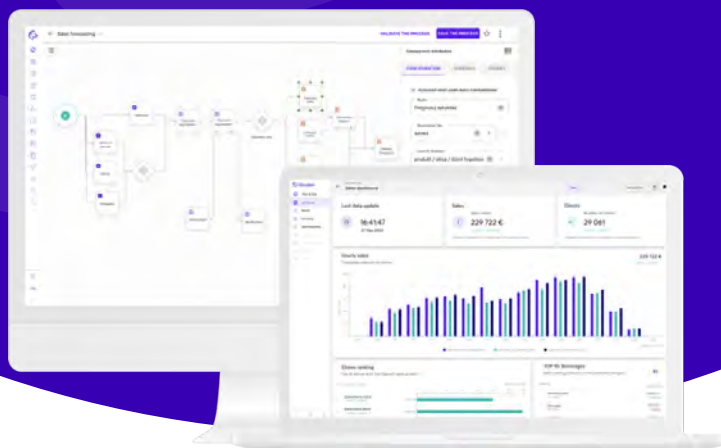
Platforma Occubee pozwala automatycznie gromadzić dane sprzedażowe, trenować modele machine learning, prognozować sprzedaż i popyt oraz generować polecenia komisjonowania i zamówienia do dostawców w celu optymalnego zatowarowania sklepów i magazynów.

Bazując na danych i sztucznej inteligencji, Occubee pozwala zwiększyć sprzedaż poprzez zwiększenie dostępności produktów w sklepach i kanale online.

Wykorzystanie Occubee poprawia działanie całego łańcucha dostaw: od zatowarowania sklepów, przez optymalne stany magazynowe dla kanałów sprzedaży offline oraz online, aż po zamówienia do dostawców i plany produkcji.

Krótkoterminowe prognozy sprzedaży dla każdego produktu i sklepu odrębnie są punktem wyjścia do automatycznego generowania list komisjonowania w magazynach. Dzięki temu możliwe jest optymalne zatowarowanie sklepów oraz unikanie out-of-stock'ów i overstock'ów.

Średnio- i długookresowe prognozy popytu dla rynku służą do zapewniania optymalnych stanów magazynowych, optymalizacji logistyki czy pracy w magazynie, a także pozwalają automatycznie generować zlecenia dla dostawców i planować produkcję.



[www.occubee.com](http://www.occubee.com)



Więcej treści znajdziesz na naszym LinkedIn 

Prezentowane informacje nie stanowią oferty w rozumieniu Kodeksu cywilnego. Wszelkie materiały tekstowe, zdjęciowe, graficzne oraz ich układ w niniejszym dokumencie stanowią własność intelektualną 3Soft S.A. i są prawnie chronione prawem autorskim oraz innymi przepisami dotyczącymi ochrony własności intelektualnej. Z zastrzeżeniem postanowień powszechnie obowiązujących przepisów prawa, ich kopiowanie lub inne wykorzystywanie dla celów komercyjnych, a także dystrybucja, modyfikacja oraz publikacja bez uprzedniej pisemnej zgody 3Soft S.A. są zabronione.