

MARKETING A PODPORA PREDAJA

Scenár digitalizácie s využitím umelej inteligencie



POPIS

AI v maloobchode sa sústreďí na kľúčové piliere digitálnej transformácie:

- Obohacuje maloobchodných zákazníkov individualizovanou/personalizovanou skúsenosťou;
- Zabezpečuje, aby maloobchodní zamestnanci poskytovali diferencované skúsenosti zákazníkom;
- Optimalizuje maloobchodný dodávateľský reťazec;
- Mení maloobchodné produkty a služby tak, aby zákazníkom doručili novú hodnotu;
- Rozširuje existujúce biznisové procesy o nové, dosiaľ nemožné.

Maloobchodné riešenia založené na dostupných AI cloudových službách umožňujú realizovať digitálnu transformáciu maloobchodu nasledujúcimi spôsobmi:

Obohatenie maloobchodných zákazníkov individualizovanou skúsenosťou:

- Transformujete spôsob, akým zákazníci začnú proces nákupu a pomocou automatizovaných postupov im pomôžete podniknúť ďalší najlepším krok;
- Analyzujete správanie a emócie zákazníkov a automaticky dodávate vysoko relevantné ponuky produktov a služieb;
- Poskytujete zákazníkovi osobného digitálneho asistenta, aby nasmeroval rozhodovanie a skrátil konverzný cyklus.

Zabezpečenie, aby maloobchodní zamestnanci poskytli diferencované skúsenosti zákazníkom:

- Tvoríte heatmapy založené na správaní zákazníkov v obchode s cieľom porozumenia, ktoré rozloženie obchodu vedie k zvýšeniu konverzných pomerov a predaja;
- Optimalizujete priestor pre regály a police a zabezpečujete, aby bol tovar vždy označený presnou cenou a zľavami;
- Automaticky upozorňujete odborných zamestnancov ak majú zákazníci konkrétne problémy s produktom alebo službou.

Optimalizácia maloobchodného dodávateľského reťazca:

- Vytvárate presnejšie dopytové prognózy a cenové informácie založené na automaticky zbieraných verejných a zákazníckych údajoch;
- Optimalizujete doručenia objednávok a znižujete náklady pomocou lokalizácie zákazníka a jeho predpokladaného pohybu za účelom plánovania plnení distribuovaných objednávok;
- Automatizujete procesy dopĺňania zásob a optimalizujete riadenie zásob.

Zmena maloobchodných produktov a služieb tak, aby zákazníkovi poskytli novú hodnotu:

- Identifikujete preferencie zákazníka z viacerých zdrojov a porovnávate ich s najrelevantnejším zdrojom zásob;
- Umožňujete zákazníkovi testovať, skúšať a prispôbovať produkty v predajni;
- Agregujete a analyzujete náklady a správanie zákazníka zachytené v priebehu nákupu za účelom ďalšieho doladenia zákazníckej nákupnej cesty.

Rozšírenie existujúcich biznis procesov o nové, dosiaľ nemožné, či neexistujúce:

- Koncept „digitálneho dvojčata“ – vďaka edge technológiám a spracovaniu informácií v reálnom čase sa vyskytuje možnosť vytvoriť digitálnu kópiu fyzického produktu a uchovanie informácií vo vzťahu k danému fyzickému produktu. Príklad: vďaka zabudovaniu RFID alebo bluetooth senzorov do tenisiek vieme pomocou mobilnej aplikácie sledovať počet zvládnutých kilometrov, celkový čas tréningu a pod;
- Vďaka prepojenosti informačných systémov na úrovni v reálnom čase má zákazník možnosť zasahovať do výrobných procesov a konfigurovať budúce výrobky podľa svojich predstáv;
- Možnosť rozšíriť biznis procesy o nové, dosiaľ nemožné – vďaka vyššie uvedeným možnostiam zavedenia mobilnej aplikácie pre akumuláciu a spracovanie digitálnych informácií o konkrétnom produkte sa otvára výrobcovi možnosť monetizácie danej mobilnej aplikácie, napríklad formou rôznych edícií týchto aplikácií pre zákazníkov (licenčný plán PRO/Premium, standard a pod), na základe zakúpenej licencie má zákazník prístup k presnejším a personalizovanejším informáciám;
- Koncept „partnera pre zákazníka“ pri dosiahnutí cieľov zákazníka – prechod od ponuky len tovaru (predaj tenisiek) k ponuke služby (dosiahnutie lepších výsledkov).

PREDPOKLADY

Proces

Retail je veľmi široké odvetvie a s jeho šírkou narastajú aj možnosti použitia technológií za účelom zlepšovania hospodárskych výsledkov firmy a zvýšenia spokojnosti spotrebiteľov.

Firma ako celok a zvlášť retailová sieť, ktorá obsluhuje veľa pobočiek, má k dispozícii obrovské množstvo interných dát. Za interné dáta považujeme tie, ktoré majú pôvod vo firme, alebo sú jej vlastníctvom (informácie o zákazníkoch, predajné dáta, skladové dáta, údaje z vernostného systému a pod.)

Spracovanie takéhoto veľkého objemu dát vie byť nákladné z hľadiska finančného, ale aj časového. Preto je dôležité ešte pred samotnou implementáciou akejkoľvek technológie mať stanovený jasný cieľ – čo chceme získať implementáciou danej technológie. Takáto požiadavka by mala vychádzať z biznisu.

Príklady biznisových cieľov:

- Zvýšiť predaj zákazníkom v danom segmente (nie segmentácia zákazníkov);
- Zvýšiť podiel zákazníkov využívajúcich vernostný program;
- Zvýšiť odpredaj starých skladových položiek za najvyššiu možnú cenu (nie optimalizovať skladové zásoby na pobočkových skladoch);
- Zvýšiť hodnotu priemerného košíka o xy %;
- Zvýšiť hodnotu UPT (Units Per Transaction) na úroveň 2,5;
- Zlepšiť hodnotenie mobilných aplikácií na Google Play/AppStore o 2 hviezdičky;
- Zvýšiť doručiteľnosť newslettera/výtlak newslettera o xy %;
- Znížiť odchody zákazníkov dlho čakajúcich pri pokladni;
- Zvýšiť návštevnosť webových stránok výrobcu alebo dodávateľa;
- Navýšenie času, ktorý zákazníci strávia na webe;
- Zvýšenie online konverzií.

Ako je možné vidieť na uvedených príkladoch, vymedzujú sa na konkrétnu úlohu. Na to, aby retailer takúto misiu splnil, potrebuje nahliadnúť len do časti svojich dát. Ak ideme zvyšovať doručiteľnosť newslettera, (napr. vo vzťahu ku konverznnej miere), zo všetkých dostupných (interných) dát nás zaujíma predovšetkým tabuľka s odberateľmi. Pre newsletter však nie sú podstatné všetky polia tejto tabuľky. Preto sa v prvom kroku pri kontrole dátovej kvality zameriame na polia, ktoré sú pre túto úlohu kľúčové. Napr. meno, priezvisko, e-mail.

Až z konkrétneho prípadu, ktorý ideme riešiť, následne „vypadnú“ potrebné nástroje, ľudia, oddelenia a procesy, ktoré bude treba vo vzťahu k úlohe spraviť. Môže sa teda stať, že danú úlohu vyriešime aj bez použitia drahých a zložitých technológií.

Celý proces stojí a padá na najspodnejšej vrstve a tou sú dáta, konkrétne ich kvalita. Jednotlivé poschodia tzv. DIKW pyramídy si môžeme predstaviť ako formy analytiky – od deskriptívnej (Data), cez diagnostickú (Information), prediktívnu (Knowledge), až po preskriptívnu (Wisdom).

Pokiaľ nebudeme mať zvládnuté elementárne procesy na najspodnejšej vrstve, ktorými nastavujeme kvalitu, všetky ďalšie vrstvy budú mať nedôveryhodné výstupy a celá analytika bude nespoľahlivá.

Deskriptívna analytika – je základná analýza, ktorá štandardne dáva odpoveď na otázku: Čo sa stalo? Štandardne si ju vieme predstaviť ako kontingenčnú tabuľku v Exceli. Už tento jednoduchý pohľad nám povie veľa o dátovej kvalite. Je preto nevyhnutné zvládnuť tieto základy ak chceme ďalej skúmať dáta a podrobovať ich ďalším metódam.

Diagnostická analytika – ide o prvú z foriem pokročilej analytiky. Táto odpovedá na otázku: prečo sa to stalo? V tomto prípade podrobujeme dáta ďalším technikám ako sú drilldowny, aplikácia štatistických metód, data mining a podobne.

Prediktívna analytika – tu už môžeme hovoriť aj o formách umelej inteligencie a neurónových sieťach. Štandardne dáva odpoveď na otázky: Čo sa stane? Ako sa budú vyvíjať kľúčové ukazovatele do budúcnosti? Koľko ľudí môžeme očakávať na kamenných prevádzkach?

Preskriptívna analytika – často označovaná ako konečná hranica analytických možností podniku. Len veľmi málo firiem ju má dobre zvládnutú. Častokrát ide o veľké firmy a technologických gigantov, ktorí majú k dispozícii veľa dát. S rastúcimi investíciami do nových technológií a rýchlym rozvojom startupov prichádza vlna rôznych riešení práve pre tento typ analytiky. Tieto algoritmy sa však stále budú opierať o interné dáta firmy, na ktoré budú kladené veľmi vysoké nároky z pohľadu dátovej kvality. Preskriptívna analytika odpovedá na otázku: Čo mám urobiť?

Dáta

Základným predpokladom na nasadenie akejkoľvek technológie – machine learning nevynímajúc – sú kvalitné dáta. Tie existujú zväčša len v ideálnom prostredí a v realite sú skôr raritou. Kvalita dát sa nedá spraviť plošne. Bolo by veľmi komplikované a nákladné opraviť a zjednotiť všetky dáta, ktoré podnik má. Treba myslieť aj na to, že zlepšovanie kvality dát nie je len o samotnom dopĺňaní databáz a oprave jednotlivých PDE (Physical Data Element) a oprave štruktúr. Zavedenie kvality dát je najmä o procesoch a tie bývajú najdrahšie. To, že opravíme dáta a vytvoríme „stav 0“ ešte neznamená, že o rok sa opäť nedostaneme do nevyhovujúceho stavu.

Preto ak máme zmysluplne využiť technológie, a teda aj strojové učenie, mali by byť všetky nasadenia podriadené biznisovému cieľu. Až keď máme konkrétny cieľ, môžeme vybrať ktoré dáta na tento účel použijeme a nad týmito dátami začneme nastavovať kvalitu dát.

Z hľadiska použitia vieme dáta segmentovať do jednoduchej matice:

- Interné - externé;
- Štruktúrované - neštruktúrované.

Podľa použitia vieme následne vybrať vhodné aplikácie alebo databázy, ktoré nám dáta budú podsúvať.

Výhodou spoločností, ktoré sa zameriavajú na predaj koncovému zákazníkovi je, že majú k dispozícii veľké množstvo štruktúrovaných dát použiteľných aj pre strojové učenie.

Devízou štruktúrovaných dát je ich konkrétnosť. Ak máme kvalitu dát na dobrej úrovni, vieme z týchto údajov získať veľa aj bez použitia umelej inteligencie.

Skutočný poklad sa však ukrýva v dátach neštruktúrovaných. Pod týmto pojmom si môžeme predstaviť napríklad e-mailovú komunikáciu, nahrávky telefonických rozhovorov, videá z in-store kamier, ale aj facebookové príspevky a komentáre, diskusie a rôzne iné formy online komunikácie. Na analýzu tejto formy dát je strojové učenie výborným pomocníkom.

Prepojením týchto dát so štruktúrovanými dostaneme nový pohľad na zákazníka a vieme sa zamerať na kľúčové ukazovatele, ktoré majú vyššiu pridanú hodnotu, prípadne nám vedú rozšíriť pohľad na naše štandardné KPI.

Je iné pozeráť sa na ukazovateľ UPT (počet položiek na účtenke) vo vzťahu k transakčným dátam a je iné na toto isté číslo nazrieť cez zóny, v ktorých zákazníci trávajú najviac času. Informácie o tom nám vedú poskytnúť kamery a softvér, ktorý tieto zábery vyhodnotí. Následne môžeme aj podľa transakčných dát nastaviť jednotlivé zóny tak, aby zákazníkovi dávali zmysel.

Aplikácie

Veľa firiem funguje na takzvaný „technologický dlh“. Znamená to, že zvyšovanie požiadaviek na zavedenie nových technológií bolo zo strany firmy dlhodobo zanedbávané a potláčané, pretože manažment v týchto investíciách nevidel priamy finančný návrat.

Výsledkom bolo, že tieto potreby boli kompromisne splnené ohýbaním existujúcich systémov do čiastočne vyhovujúceho stavu, prípadne aplikáciou rôznych iných krátkodobých riešení. Nie je výnimkou, že spoločnosť, ktorá dokáže generovať miliónové obraty, beží na jednom ERP, ktorého súčasťou je všetko - od fakturácií, skladového hospodárstva, CRM, cez obsluhu webových portálov až po zber dát z počítačiel zákazníkov.

Príklad:

Chceme zmerať konverznú mieru v jednotlivých predajniach. Na to, aby sme vedeli vypočítať tento ukazovateľ potrebujeme: transakčné dáta z pokladní (ERP), zoznam prevádzok (ERP), dáta z počítačiel zákazníkov. Z dátovej matice vyplýva, že ide o interné štruktúrované dáta. Úlohou ETL bude:

- V rámci procesu extrakcie stiahnuť dáta z počítačiel a transakčné dáta. Väčšina ERP automaticky priraďuje účtenky jednotlivým strediskám (predajniam), takže v jednej tabuľke už máme spárovanú účtenku ku konkrétnej predajni;
- V transformačnom procese musíme zosumarizovať počty účteniek pre každé stredisko - ideálne po hodinách a ku každej prevádzke doplniť počet návštev. Tieto musia byť sumarizované tiež v rovnakej časovej granularite.

Vždy po pridaní nového modulu sa síce tento problém vyriešil, ale iba naoko. Akýkoľvek ďalší zásah alebo zmena tohoto systému si bude do budúcnosti vyžadovať dôkladnú dopadovú analýzu, testovanie a množstvo premrhaných interných ľudských hodín. Skôr či neskôr každý narazí na limit systému a bude nutná jeho kompletná výmena. S narastajúcim počtom zdrojov dát sa tento moment blíži exponenciálne. Migrácia hlavného systému vie trvať roky a pre väčšie podniky vie mať nepodarená výmena nosnej aplikácie fatálne následky.

Záleží od konkrétneho prípadu, zvyčajne však platí, že každú časť procesu by mala obsluhovať aplikácia, ktorá je primárne na to určená.

V retaile je veľmi dôležitá analytika a rýchle vyhodnocovanie zákazníckych dát. Tá primárne vychádza z transakčných dát (vydané bloky, faktúry). Na tieto dáta vieme následne naviazať dáta z ďalších zdrojov. Záleží od povahy údajov, či ich budeme na transakčné dáta prepájať cez unikátne identifikátory, alebo cez časovú značku (timestamp). Keď máme pripravený dataset a máme k nemu biznis case, môžeme prejsť k samotnej analytike.

Infraštruktúra

Ideálnym stavom je existencia tzv. data lake. Zjednodušene sa dá povedať, že ide o úložisko, do ktorého je možné ukladať veľké množstvo štruktúrovaných, pološtruktúrovaných a neštruktúrovaných dát. Je to miesto na ukladanie všetkých typov dát v ich natívnom formáte bez pevných limitov na veľkosť. Na rozdiel od bežných DWH (Data Warehouses - dátových skladov), kde sú údaje ukladané hierarchicky, data lake má plochú architektúru. Každý dátový prvok má jedinečný identifikátor a je označený súborom metadát.

Pre malé a stredné firmy predstavuje investícia do takejto infraštruktúry vysoké náklady s častokrát neistým výsledkom. Na trhu existujú aj cloudové riešenia pre tento segment, kľúčovú rolu zohráva kvalitný ETL systém. Ide o skratku Extract-Transfer-Load a je to softvér, ktorý dokáže získať dáta z rôznych zdrojov, transformovať ich do celku, ktorý dáva zmysel a poskytnúť ich v ucelenej forme používateľovi. Používateľom sa v tomto prípade okrem človeka rozumie aj iný dátový produkt alebo aplikačné programové rozhranie (API).

V poslednom kroku sa takto pospájané dáta publikujú pre ďalšie aplikácie. Výsledná tabuľka môže následne slúžiť ako dátový zdroj pre Business Intelligence (analytické nástroje), prípadne môže byť spracovaná ďalej v Exceli.

Je zrejmé, že v rámci transformácie nedopočítavame samotnú konverznú mieru. Ide o vypočítaný ukazovateľ a výpočet nechávame na analytika. Dôvodom je, že v analytickej vrstve vieme okrem vzorca na výpočet konverznej miery (počet účteniek/počet návštev * 100) zohľadniť aj konštantu, ktorá ráta s chybou počítadiel, prípadne ošetriť stavy, kedy by nám mohla konverzná miera vzrásť nad 100 % (ak jeden zákazník vyrobí viac ako jeden pokladničný doklad), prípadne odstrániť z výpočtov storná a reklamácie.

Toto bol veľmi jednoduchý príklad. V praxi sa bežne v rámci transformačného procesu dáta spracovávajú pomocou zložitých skriptov a neurónových sietí. Výsledkom môžu byť podklady pre prediktívnu a preskriptívnu analytiku.

Ludia

Veľmi dôležitú úlohu zohráva práve doménový expert, ktorý má okrem biznisových znalostí aj prehľad o technológiách a rozumie im aj po technickej stránke. Nie je nutné aby ovládal SQL a programovacie jazyky, je dôležité, aby rozumel ich princípu a logike. Jeho najsilnejší skill-set však musí byť z odboru, v ktorom firma podniká, prípadne z odboru riešenia konkrétnej problematiky.

Do toho však vstupuje ďalší rad skúseností, ktoré takémuto človeku umožňujú efektívnu komunikáciu s technickými ľuďmi, a čo je dôležitejšie, dokáže ich prácu aj skontrolovať.

Profily na strane zadávateľa:

- Pracovníci zodpovední za riadenie predajní;
- Pracovníci zodpovední za plánovanie;
- Experti so znalosťou retailovej analytiky a KPI s metodikami ich výpočtu;
- Experti na plánogramy a zonáciu predajní;
- Ďalšie profily s doménovou expertízou;
- Pracovník zodpovedný za priebeh projektu ako celku.

Profily s IKT zameraním, či už v internom tíme, alebo na strane dodávateľa, poprípade zamestnanci:

- Dátoví inžinieri spravujú dáta a príslušnú dátovú platformu, aby bola plne funkčná pre analýzu;
- Dátoví vedci, ktorí pripravujú, študujú, vizualizujú a modelujú dáta na platforme dátovej vedy;
- Experti na vizualizáciu a interpretáciu dát;
- IT architekti spravujú základnú infraštruktúru potrebnú pre podporu dátovej vedy;
- Vývojári aplikácií so znalosťou machine learning algoritmov (Python, R a iných), ktorí nasadzujú modely do aplikácií s cieľom vytvárania produktov založených na dátach;
- Programátori a ďalší IKT špecialisti zodpovedajú za implementáciu riešenia tak po stránke softvéru aj hardvéru;
- Konzultant so znalosťami základov dátovej etiky;
- Konzultanti so znalosťami GDPR;
- Integrovaní špecialisti so znalosťou REST alebo SOAP technológií komunikácie;
- Správca databáz.

Organizácia

Kľúčovým faktorom úspechu akejkoľvek iniciatívy v oblasti data science je správny tím. Rola data scientist je pomerne nová a vyžaduje kombinácie schopností, ktoré doteraz neboli bežné. Je takmer nemožné nájsť človeka, ktorý vie pokryť tieto schopnosti samostatne end-to-end. Preto je dôležité mať správnu tímovú dynamiku a správne zloženie tímu.

Záleží od možností firmy a jej veľkosti, ako jednotlivé roly obsadí. Dôležité je aj to, či vytvorí trvalý tím, alebo len pracovnú skupinu, ktorá bude mať za úlohu vyriešiť konkrétnu úlohu.

Ak firma nemá dostatok prostriedkov na nábor alebo nie je možné navyšovať počty zamestnancov z iných dôvodov, dá sa pristúpiť aj k outsourcingu. Trendom najmä väčších firiem je neoutsourcovať ľudí, ktorí sa venujú vývoju a podieľajú sa na tvorbe know-how. Takíto externisti sa ľahko dostávajú k algoritmom, ktoré často predstavujú konkurenčnú výhodu. Zmluvy o mlčanlivosti sa väčšinou vzťahujú na konkrétne dáta. Algoritmus, ktorého vývoj si firma zaplatí u kontraktora, sa môže veľmi ľahko stať jeho obchodovateľným produktom a spoločnosť tak riskuje stratu konkurenčnej výhody.

PRÍNOSY

Kvalitatívne prínosy/kvantitatívne prínosy

AI môže v maloobchode posilniť prakticky všetky obchodné funkcie. Zatiaľ čo sa niektoré ľahko realizujú (dostupnosť dát, overené ML modely a ďalšie), iné poskytujú maloobchodníkovi väčšiu pridanú hodnotu, napríklad znížením úbytku zákazníkov. Podľa našich

skúseností k najväčším prioritám pre väčšinu maloobchodníkov patria nasledujúce štyri príklady scenárov použitia AI.

Optimalizácia zásob na báze strojového učenia (ML)

Prognóza dopytu, plánovanie tovaru, dopĺňovanie skladov: Nedostatok tovaru na sklade predstavuje najväčšiu príčinu straty predaja a nespokojnosť zákazníkov. Súčasný globálny celosvetový priemer nedostatočných zásob je 8 %; vzhľadom na to, že aspoň tretina zákazníkov nakúpi tovar u konkurenta, čoho následkom je nielen strata predaja, ale aj potenciálna strata pri ďalšom predaji a budúcich príležitostiach predaja.

Výhody pre maloobchodného zákazníka: súhrn týchto nedokončených nákupov sa premietne do straty predaja cca 4 % pre typického maloobchodníka. Pre porovnanie: americké maloobchodné predaje vzrástli o 3,5 % v roku 2017.

Druhým veľkým problémom sú nadmerné zásoby, vopred nakúpené položky, ktoré zvyšujú nároky na investície, čo v konečnom dôsledku vedie k donúteným zľavám, ktoré sa nakoniec dotýkajú prevádzkových marží maloobchodníkov. Dômyselný ML algoritmus pre prognózovanie dopytu bude brať do úvahy interné a externé dáta pre vytvorenie presnejších prognóz, ktoré sa časom neustále zlepšujú.

Optimalizácia cien na báze ML

Ďalším prípadom s dôležitým prínosom je využitie AI pre maloobchodné ceny. Maloobchodní predajcovia často nastavujú obchodné prirážky pri stanovovaní cien produktov ručne pomocou metódy cost+ alebo Keystone. Metodiky naceňovania na základe ponuky nie sú účinné tak ako varianty založené na dopyte, čo znamená, že tovar by mal byť nacený podľa toho, čo je zákazník ochotný zaplatiť vs. odporúčaná koncová cena alebo jednotková nákupná cena pre maloobchodníka. Algoritmy ML pre optimalizáciu cien budú analyzovať pružnosť ceny tovaru bez vplyvu na objem predaja.

Prínos pro maloobchodného zákazníka: priemerný obchod s potravinami v USA ponúka výber 50 – 60 000 typov tovaru. Zvýšením ceny spodného kvartilu sortimentu obchodov s potravinami v priemere 0,10 USD za tovar by sa zvýšilo celkovou prevádzkovou maržou o 1,3 %. Pre porovnanie, americké predajne potravín mali priemernú prevádzkovú maržu 1,9 %.

Zákaznícka osobná skúsenosť s ML

Ďalším efektívnym využitím AI v maloobchode je vytváranie individuálnych marketingových kampaní. Historicky väčšina maloobchodných predajcov využíva každý rok rovnaké sezónne zľavy, čo má za následok identický marketing a ceny pre každého zákazníka. Tento typ jednotného prístupu už nebude naďalej žiadaný. ML môže pomôcť určiť optimálnu komunikáciu a ceny pre špecifické skupiny zákazníkov s možnosťou cielenia až na jednotlivca. Tým sa zvýši miera reakcií, ale môže taktiež optimalizovať marže, pretože niektorí zákazníci potrebujú menšie zľavy ako ostatní, aby sme u nich vzbudili motiváciu k nákupu. Individuálna propagácia prostredníctvom CRM s využitím AI zvýši obchodu návratnosť marketingových investícií jednotlivých kampaní.

Prínos pre maloobchodného zákazníka: priemerný výnos z investícií z každého 1 USD je generovaná marža vo výške 1,09 USD. Takže pre každý 1 cent v ROI to znamená 1 % nárastu tržieb.

AI podporená nákupná cesta zákazníka

Komunikačné platformy priamo spájajú fyzické obchody s digitálnym svetom zákazníka a vytvárajú tak prepojenú skúsenosť naprieč rôznymi systémami (Omni-Channel-Experience). To pomáha zvyšovať predaj pomocou kombinácie osobnej skúsenosti v kamennej predajni s AI asistenciou a online nákupom s cieľom zvýšiť predaj a minimalizovať odklon od online nákupného košíka.

Prínos pre maloobchodného zákazníka: odlišuje sa v závislosti od typu obchodu a regiónu, ale konverzný pomer nákupu vo fyzickej predajni sa pohyboval okolo 20 % v roku 2013. Denný počet zákazníkov IKEA je 6 200, každý z nich stroví priemerne 200 USD. Každé zvýšenie konverzného pomeru o 0.1 % sa rovná 4,5 miliónom USD.

Riziká

Mnoho spoločností si pri týchto technológiách neuvedomuje tú najpodstatnejšiu vec. Použitie akýchkoľvek nástrojov pokročilej analytiky alebo umelej inteligencie je vo veľkej miere závislé od kvality dát, ktoré sú použité a platí jednoduché Trash In = Trash Out (neporiadok dnu = neporiadok von, pozn. preklad.). Uponáhľané a nepremyslené implementácie mnohokrát končia sklamaním a nulovým alebo negatívnym prínosom pre spoločnosť.



MARKETING A BODPORA PREDAJA



Tento text je súčasťou dokumentu ANALÝZA A NÁVRH MOŽNOSTÍ VÝSKUMU, VÝVOJA A APLIKÁCIE UMELEJ INTELIGENCIE NA SLOVENSKU - DIELO Č. 2 - MANUÁL PRE FIRMY NA ZAVEDENIE UMELEJ INTELIGENCIE. Dielo bolo vypracované pre Úrad podpredsedu vlády SR pre investície a informatizáciu autorským kolektívom zo Slovenskej technickej univerzity v Bratislave na základe Zmluvy o dielo č. 1024/2019 zo dňa 29. 10. 2019. Počas tvorby tejto štúdie boli jednotlivé výstupy posudzované expertným tímom združeným pod Slovenským centrom pre výskum umelej inteligencie - Slovak.AI, ktorého členom je aj Slovenská technická univerzita v Bratislave. Všetky závery a komentáre v správe odzrkadľujú názory a postoje autorského kolektívu, ktoré sa opierajú o výsledky analýz opísaných v správe a o diskusie s odborníkmi na problematiku umelej inteligencie spolupracujúcimi na tejto správe. Všetky údaje v tomto texte, ak nie je uvedené inak, sú aktuálne k dátumu odovzdania správy.

© 2019, 2020 Slovenská technická univerzita v Bratislave, Úrad podpredsedu vlády SR pre investície a informatizáciu. Všetky práva vyhradené.