

EKONOMICKÁ UNIVERZITA V BRATISLAVE

OBCHODNÁ FAKULTA

Evidenčné číslo: 102007/I/2021/36114651034450436

**PREDIKTÍVNE MARKETINGOVÉ ANALÝZY
PROSTREDNÍCTVOM NÁSTROJOV UMELEJ INTELIGENCIE**

Diplomová práca

2021

Dionýz Bréda, Bc.

EKONOMICKÁ UNIVERZITA V BRATISLAVE
OBCHODNÁ FAKULTA

Evidenčné číslo: 102007/I/2021/36114651034450436

PREDIKTÍVNE MARKETINGOVÉ ANALÝZY
PROSTREDNÍCTVOM NÁSTROJOV UMELEJ INTELIGENCIE

Diplomová práca

Študijný program: marketingový a obchodný manažment

Študijný odbor: ekonómia a manažment

Školiace pracovisko: Katedra informatiky obchodných firiem

Vedúci záverečnej práce: Peter Červenka, Ing., PhD.

Bratislava 2021

Dionýz Bréda, Bc.

Pod'akovanie

Úprimne d'akujem vedúcemu mojej diplomovej práce Ing. Petrovi Červenkov, PhD.
Za odborné vedenie a cenné rady, ktoré mi pomohli pri vypracovaní práce.

ABSTRAKT

BREDA, Dionýz: Prediktívne marketingové analýzy prostredníctvom nástrojov umelej inteligencie. – Ekonomická univerzita v Bratislave. Obchodná fakulta; Katedra marketingu. – Vedúci záverečnej práce: Ing. Peter Červenka, PhD. – Bratislava: OF EU, 2021, 63s.

Cieľom záverečnej práce je zistiť spôsoby využitia prediktívnej marketingovej analýzy prostredníctvom nástrojov umelej inteligencie. Práca je rozdelená do štyroch kapitol. Obsahuje dva obrázky a jednu tabuľku. Prvá kapitola je venovaná súčasným analytickým nástrojom využívaných v marketingu, vrátane predstavenia nových trendov v spracovaní a analýze dát, a aj charakteristiku základných atribútov umelej inteligencie, ktorými sú umelé neurónové siete a hlboké učenie. Ďalšia časť tejto kapitoly je venovaná predikcii, jej prínosu a využitiu v marketingu. Záverečná kapitola sa zaoberá konkrétnym príkladom využitia marketingovej predikčnej analýzy prostredníctvom umelej inteligencie spoločnosti Amazon na patentovanom projekte s názvom „predbežné doručenie“.

Kľúčové slová:

Predikcia, marketing, analýza, veľké dáta, umelá inteligencia

ABSTRACT

BREDA, Dionýz: Predictive marketing analyzes using artificial intelligence tools. - University of Economics in Bratislava. Faculty of Commerce; Department of Marketing. - Thesis supervisor: Ing. Peter Červenka, Ph.D. - Bratislava: OF EU, 2021, 62p.

The aim of the final work is to find out the ways of using predictive marketing analysis through artificial intelligence tools. The work is divided into four chapters. It contains two pictures and one table. The first chapter is devoted to the current analytical tools used in marketing, including the introduction of new trends in data processing and analysis, as well as the characteristics of the basic attributes of artificial intelligence, which are artificial neural networks and deep learning. The next part of this chapter is devoted to prediction, its benefits and use in marketing. The final chapter deals with a specific example of the use of marketing predictive analysis through artificial intelligence of Amazon on a patented project called "anticipatory shipping".

Keywords:

Prediction, marketing, analysis, big data, artificial intelligence.

1. Obsah

Úvod	7
1. Súčasný stav riešenej problematiky doma a v zahraničí.....	9
1.1. Marketing a potreba analýz	9
1.1.1. Veľké dáta veľká príležitosť.....	11
1.1.2. Prediktívna analýza	11
1.2. Súčasný analytické nástroje marketingu	14
1.2.1. Nástroje založené na udalostiach	14
1.2.2. Nástroje orientované na premávku	15
1.2.3. Analytické nástroje vyhľadávačov	17
1.2.4. Nástroje marketingových panelov	17
1.2.5. Nástroje vizuálneho správania	18
1.2.6. A / B testovacie nástroje	19
1.3. Nové trendy analýzy dát	19
1.3.1. Pokročilá analýza dát.....	20
1.3.2. Kontinuálna inteligencia.....	20
1.3.3. Digitálne dvojčatá.....	21
1.3.4. Dátové rozprávanie údajov - Data Storytelling	21
1.3.5. DataOps.....	22
1.3.6. Hybridné nasadenie	22
1.4. Neurónové siete.....	22
1.4.1. Výstavba umelej neurónovej siete.....	23
1.4.2. Ako funguje umelá neurónová sieť	25
1.4.3. Aplikácie umelých neurónových sietí.....	25
1.4.4. Typy umelých neurónových sietí.....	26
1.5. Deep learning	28
1.6. Definícia hlbokého učenia	29
1.6.1. Základný koncept hlbokého učenia.....	30
1.6.2. Ako funguje hlboké učenie.....	30
1.6.3. Rozdiel medzi strojovým učením a hlbokým učením.....	31
1.6.4. Príklad hlbokého učenia	31
1.6.5. Aplikácia hlbokého učenia.....	32

1.6.6.	Oblasti využitia pre hlboké učenie	32
1.7.	Prediktívny marketing	33
1.7.1.	Definícia predikcie	33
1.7.2.	Definícia prediktívneho marketingu	34
1.7.3.	Dôležitosť prediktívneho marketingu na trhu	34
1.7.4.	Vzostup prediktívneho marketingu	35
1.7.5.	Ako funguje prediktívny marketing	35
1.7.6.	Typy riešení prediktívneho marketingu	36
1.7.7.	Výhody prediktívneho marketingu	37
1.7.8.	Prediktívne marketingové výzvy	37
1.7.9.	Príklady použitia prediktívneho marketingu	38
1.7.10.	Využitie technológie prediktívneho marketingu	39
1.8.	Umelá inteligencia v marketingu	40
1.8.1.	Príklady aplikácií umelej inteligencie v marketingu	40
2.	Cieľ práce	47
3.	Metodika práce a metódy skúmania	48
4.	Výsledky práce	49
4.1.	Profil spoločnosti Amazon	49
4.1.1.	Finančné výsledky Amazon.com	50
4.1.2.	Amazon ako zamestnávateľ	52
4.2.	Model predvídaveho doručenia	53
4.2.1.	Úloha veľkých dát	54
4.2.2.	Pridaná hodnota a vplyv na dodávateľský reťazec	55
4.2.3.	Vplyv na konečného zákazníka	56
4.3.	SWOT analýza modelu predvídave doručenie	56
4.3.1.	Silné stránky	56
4.3.2.	Slabé stránky	58
4.3.3.	Príležitosti	60
4.3.4.	Hrozby	61
4.4.	Prieskum verejnej mienky	64
4.5.	Zhrnutie výsledkov práce	72
4.5.1.	Návrhy riešení	73
4.5.2.	Vyhodnotenie	75
	Záver	76
	Zoznam použitej literatúry	77

Úvod

Pojem a význam marketingu sa v porovnaní s predchádzajúcimi obdobiami výrazne zmenili. V dnešnom marketingovom význame je pre spoločnosti čoraz dôležitejšia cieľená digitálna reklama. Dramaticky sa zmenili aj komunikačné kanály a správanie spotrebiteľov. Zatiaľ čo v 90. rokoch stačilo posielat' reklamy a prevádzkovať reklamy, dnes to musí byť aj online marketing.

Online marketing je za posledných desať rokov čoraz dôležitejší. Dôvodom je celosvetové šírenie digitálnych médií. To prinútilo reklamné spoločnosti prehodnotiť svoj marketingový koncept. Dôraz na digitálny prístup mal za následok aj zmenu nákupného správania. Každý spotrebiteľ, ktorý má prístup k počítaču a internetu, si pred kúpou produktu najskôr vyhladá informácie na internete. Číta články o hľadanom produkte na spotrebiteľských portáloch a navzájom porovnáva rôzne ponuky. V minulosti sa väčšina predaja generovala prostredníctvom predaja v továrňach alebo obchodoch. Na druhej strane dnes vedenie spoločnosti dosahuje vyššie tržby pomocou opatrení online marketingu a novších nástrojov digitálneho marketingu (sociálne médiá). Aby spoločnosti dokázali prežiť v konkurencii, musia prispôbiť svoje marketingové opatrenia marketingovému významu súčasnosti.

Zmenil sa aj pojem zákazník. Vďaka ľahšiemu prístupu k informáciám v porovnaní s predchádzajúcimi dobami sú potenciálni kupujúci kritickejší. Preferujú výrobky, ktoré kupujúci pozitívne hodnotia. V tejto súvislosti je potrebné vnímať aj analýzy spokojnosti zákazníkov vykonané mnohými spoločnosťami. Zmenený marketingový význam dnes rozšíril aj obsahový obsah reklamného kanála. Klasický marketingový mix sa rozšíril o digitálne kanály, v závislosti od obchodného modelu môže online marketing dokonca prevládať.

1. Súčasný stav riešenej problematiky doma a v zahraničí

Hal Varian, hlavný ekonóm spoločnosti Google, v roku 2013 uviedol: „Pred miliardou hodín sa objavil homo sapiens. Pred miliardami minút sa začalo kresťanstvo. Pred miliardou sekúnd bolo vydané IBM PC. Pred miliardou vyhľadávaní ... bolo dnes ráno.¹“

Vyšší marketingový význam je dnes prospešný pre riadenie podniku v dôsledku internetu. Moderné softvérové riešenia poskytujú všetkým oddeleniam rýchly prístup k potrebným informáciám. Pohodlná komunikácia cez internet zvyšuje spokojnosť zákazníkov prostredníctvom rýchlej spätnej väzby. Okrem toho internet ponúka možnosť kedykoľvek cielene využiť marketing vo vyhľadávačoch, obsahový marketing, e-mailový marketing, marketing bulletinov a ďalšie digitálne kanály marketingového mixu. Nástroje digitálnej analýzy sú čoraz sofistikovanejšie, čo dáva podnikovému manažmentu príležitosť robiť prospešnejšie obchodné rozhodnutia.

1.1. Marketing a potreba analýz

Po celé desaťročia bolo podnikanie do istej miery špekulatívnym podnikaním. Reklamné kampane neobsahovali žiadne priame mechanizmy sledovania. Zhromažďovanie demografických informácií a informácií o životnom štýle zákazníkov si vyžadovalo telefonické úsilie s nízkou odozvou a manuálny zber údajov. Aj keď boli údaje k dispozícii, mechanizmy na skúmanie, porovnávanie a využitie týchto informácií boli obmedzené. Väčšie spoločnosti mali zdroje na získavanie údajov zo svojej zákazníckej základne, ale najmä malé podniky boli nútené pracovať v ekosystéme, ktorý bol podľa dnešných štandardov neprehľadný.

Svet podnikania sa rýchlo mení a s ním aj marketing. V informačnom veku hru menia dáta. Údaje sa stávajú nevyhnutnosťou pre všetkých obchodníkov, najmä prichádzajúcich obchodníkov, a poskytnuté poznatky sú dôležité a ľahko dostupné pre tých, ktorí vedľa, kde hľadať. Tento trend svedčí o tom, že moderní spotrebitelia požadujú osobný a pohodlný

¹ Ajay Agrawal, J. G. (2018). *Prediction Machines: The Simple Economics of Artificial Intelligence*.

zážitok, ktorý konkrétne vyhovuje ich potrebám, nie všeobecné očakávania homogenizovaného davu. Zhromažďovanie a analýza údajov, najmä v objemoch, ktoré umožňuje internet, poskytuje lepší prehľad o živote, preferenciách a želaniach zákazníkov. Okrem toho ponúka lepší prehľad o efektívnosti obchodných postupov a stratégií a poskytuje konkrétne, uplatniteľné informácie, na ktorých možno zakladať dôležité rozhodnutia v nespočetných obchodných kontextoch.

Pokrok v technológiách, ako sú výpočty v pamäti, a nárast masívnych paralelných platforiem otvoreného zdroja sú ďalšími príležitosťami na využitie súborov veľkých dát. Tieto platformy pre veľké údaje uľahčujú rýchle prijímanie údajov nákladovo efektívnym spôsobom a umožňujú analýzu údajov v reálnom čase.

Digitálni spotrebitelia sú neustále pripojení prostredníctvom svojich inteligentných telefónov, tabletov, herných konzol a takmer každej aplikácie, služby a kanála prístupného prostredníctvom týchto zariadení. Pri pohybe medzi zariadeniami a kanálmi vytvárajú niekoľko kontaktných bodov pre zákazníkov na rôznych médiách - online, offline, proprietárne, externé, podnikové siete, sociálne siete, miestne a mobilné. Pre marketingových pracovníkov sú tieto informácie vynikajúcou príležitosťou na lepšie zacelenie na ich spotrebiteľov. Maloobchodníci prijali pokročilé analytické nástroje, ako napríklad operačný výskum, aby svojim zákazníkom online poskytl prispôbené odporúčania.

Nový kontext údajov okolo zákazníkov Veľkými dátami sa vo veľkej miere rozumie neustále sa zvyšujúca záplava dát, pokiaľ ide o objem, rozmanitosť, rýchlosť a zložitosť, ktorá sa generuje v dnešnom digitálnom ekosystéme. Ako je znázornené na obrázku 1, veľké súbory údajov sa generujú okolo zákazníkov na základe ich online nákupov, kliknutí na webe, aktivít v sociálnych sieťach, inteligentných pripojených zariadení, geografického umiestnenia atď. Zákazníci vytvárajú nové údaje pri každom kroku, ktorý podniknú, či už ide o štruktúrované údaje, pri preklikávaní webových stránok alebo neštruktúrovaných údajov pri zverejňovaní komentárov na Facebooku. Pomocou technológií veľkých dát a analytických metód môžu obchodníci ťažiť, kombinovať a analyzovať oba typy údajov v takmer reálnom čase. To im môže pomôcť odhaliť skryté vzorce, napríklad spôsob interakcie rôznych skupín zákazníkov a spôsob, akým to vedie k rozhodovaniu o nákupe. Na základe týchto poznatkov môžu spoločnosti potom vyvíjať ciele marketingové kampane, ktoré zodpovedajú individuálnym preferenciám zákazníka.

1.1.1. Veľké dáta veľká príležitosť

„Veľké dáta“ často evokujú obraz veľkých a zložitých kampaní vyžadujúcich sofistikovanú analýzu. Zber údajov je však oveľa jednoduchší. S výhodami veľkých dát prichádza aj potreba spoločností lepšie využívať tieto dáta na „výrazné zjednodušenie úloh, ktoré predtým mohli vykonávať iba dátoví vedci“. Dôležitejšie však je, že „táto pokračujúca demokratizácia povedie k novým prípadom použitia, ktoré sa približujú potrebám podnikových používateľov a umožnia rýchlejší čas uvedenia aplikácií AI na trh v podniku.“

Sofistikované analytické riešenia pre veľké dáta poskytujú nové prístupy k riešeniu niektorých kľúčových marketingových imperatívov a dosahovaniu pôsobivých výsledkov. Tieto riešenia môžu transformovať tradičné marketingové role a vylepšiť spôsob vykonávania základných marketingových funkcií. Obchodníci zhromažďujú údaje získané z rôznych živých kontaktných bodov zákazníkov, aby vytvorili úplný obraz o správaní každého zákazníka. Analýza tohto veľkého množstva dát v pohybe umožňuje marketingovým pracovníkom doladiť modely segmentácie zákazníkov a uplatniť poznatky pri vývoji stratégií zapojenia zákazníka a zlepšovaní hodnoty interakcie so zákazníkom.

So zvyšujúcim sa počtom zákazníckych kanálov musia marketingoví pracovníci zabezpečiť, aby poskytovali prispôsobené skúsenosti vo všetkých kanáloch. Všetky tieto snahy pomáhajú poskytovať vysoko personalizovaný zážitok pri maximalizácii návratnosti investícií do marketingu. Z dlhodobého hľadiska môžu marketingoví pracovníci poskytnúť tieto nové informácie v reálnom čase späť do organizácie a ovplyvniť tak vývoj produktov a ich ceny.

1.1.2. Prediktívna analýza

V 17. storočí John Dryden napísal: „Ak hľadáte perly, musíte sa ponoriť hlboko.“ Aj keď autor nemal na mysli pokročilú analýzu údajov, tento citát dokonale popisuje ich podstatu.

Prediktívna analýza je použitie údajov, štatistických algoritmov a techník strojového učenia na identifikáciu pravdepodobnosti budúcich výsledkov na základe historických údajov. Cieľom je ísť nad rámec vedomostí o tom, čo sa stalo, poskytnúť najlepšie hodnotenie toho, čo sa stane v budúcnosti.

Prediktívna história analýz a súčasné pokroky

Aj keď prediktívna analytika existuje už celé desaťročia, je to technológia, ktorej čas nadišiel. Čoraz viac organizácií sa zameriava na prediktívne analýzy s cieľom zvýšiť svoju spodnú hranicu a konkurenčné výhody. Prečo teraz?

- Rastúci objem a typ údajov a väčší záujem o použitie údajov na získanie cenných poznatkov.
- Rýchlejšie a lacnejšie počítače.
- Ľahšie použiteľný softvér.
- Tvrdšie ekonomické podmienky a potreba konkurenčnej diferenciácie.

S čoraz rozšírenejším interaktívnym a ľahko použiteľným softvérom už prediktívna analýza nie je iba doménou matematikov a štatistikov. Tieto technológie využívajú aj obchodní analytici a odborníci v odbore. Prediktívna analýza sa používa na stanovenie odpovedí alebo nákupov zákazníkov, ako aj na podporu príležitostí krížového predaja. Prediktívne modely pomáhajú podnikom prilákať, udržať a rásť ich najvýnosnejších zákazníkov.

Ako to funguje

Prediktívne modely využívajú známe výsledky na vývoj (alebo tréning) modelu, ktorý sa dá použiť na predpovedanie hodnôt pre rôzne alebo nové údaje. Modelovanie poskytuje výsledky vo forme predpovedí, ktoré predstavujú pravdepodobnosť cieľovej premennej (napríklad výnosu) na základe odhadovanej významnosti zo súboru vstupných premenných.

Tri z najbežnejšie používaných techník prediktívneho modelovania sú rozhodovacie stromy, regresia a neurónové siete.

Regresia (lineárna a logistická) je jednou z najpopulárnejších metód v štatistike. Regresná analýza odhaduje vzťahy medzi premennými. Určený pre nepretržité údaje, o ktorých sa dá predpokladať, že sledujú bežné rozdelenie, nachádza kľúčové vzory vo veľkých súboroch údajov a často sa používa na určenie toho, koľko konkrétnych faktorov, napríklad ceny, ovplyvňuje pohyb aktíva. Pomocou regresnej analýzy chceme predpovedať číslo, ktoré sa nazýva premenná odpovede alebo Y. Pri lineárnej regresii sa jedna nezávislá premenná

používa na vysvetlenie a / alebo predikciu výsledku Y. Viacnásobná regresia používa na predpovedanie výsledku dve alebo viac nezávislých premenných. Pri logistickej regresii sa predpovedajú neznáme premenné diskkrétnej premennej na základe známej hodnoty iných premenných. Premenná odozvy je kategorická, čo znamená, že môže predpokladať iba obmedzený počet hodnôt. Pri binárnej logistickej regresii má premenná odpovede iba dve hodnoty, napríklad 0 alebo 1. Pri viacnásobnej logistickej regresii môže mať premenná odpovede niekoľko úrovní, napríklad nízku, strednú a vysokú alebo 1, 2 a 3.

Rozhodovacie stromy sú klasifikačné modely, ktoré rozdeľujú údaje do podmnožín na základe kategórií vstupných premenných. To vám pomôže pochopiť cestu niekoho rozhodnutia. Rozhodovací strom vyzerá ako strom, pričom každá vetva predstavuje výber z niekoľkých alternatív a každý list predstavuje klasifikáciu alebo rozhodnutie. Tento model sleduje údaje a pokúša sa nájsť tú premennú, ktorá rozdeľuje údaje do logických skupín, ktoré sa najviac líšia. Rozhodovacie stromy sú populárne, pretože sú ľahko pochopiteľné a interpretovateľné. Dobre zvládajú aj chýbajúce hodnoty a sú užitočné pri predbežnom výbere premenných. Ak teda máte veľa chýbajúcich hodnôt alebo chcete rýchlu a ľahko interpretovateľnú odpoveď, môžete začať stromom.

Neurónové siete sú sofistikované techniky schopné modelovať extrémne zložité vzťahy. Sú populárne, pretože sú výkonné a flexibilné. Sila spočíva v ich schopnosti zvládnuť nelineárne vzťahy v dátach, čo je čoraz bežnejšie, keď zhromaždíme viac údajov. Často sa používajú na potvrdenie zistení jednoduchých techník, ako sú regresné a rozhodovacie stromy. Neurónové siete sú založené na rozpoznávaní vzorov a niektorých procesoch AI, ktoré graficky „modelujú“ parametre. Fungujú dobre, keď nie je známy žiadny matematický vzorec, ktorý by vzťahoval vstupy k výstupom, predikcia je dôležitejšia ako vysvetlenie alebo existuje veľa tréningových údajov. Umelé neurónové siete pôvodne vyvinuli vedci, ktorí sa snažili napodobniť neurofyziológiu ľudského mozgu.

1.2. Súčasné analytické nástroje marketingu

Prijímanie rozhodnutí na základe údajov je kľúčom k úspešnému marketingu. Výber správnych nástrojov marketingovej analýzy, správne meranie údajov a optimalizácia marketingového úsilia podľa nich bude znamenať rozdiel medzi nedosiahnutím vašich marketingových cieľov a ich úplným prevalcovaním.

Digitálni marketingoví pracovníci by mali mať spôsob riadenia a merania výkonnosti svojich marketingových kampaní. Presne to im pomáhajú dosiahnuť nástroje marketingovej analýzy. Nástroje marketingovej analýzy pomáhajú marketingovým pracovníkom zlepšovať svoje úsilie a dokázať svoju hodnotu. Ich cieľom je zefektívniť marketingové aktivity a zdôvodniť investíciu.

Nástroje marketingovej analýzy sú schopné zhromažďovať údaje zo všetkých kanálov vo vašom marketingovom mixe a spoločne o nich reportovať. Uľahčujú marketingovým pracovníkom generovanie správ bez toho, aby sa spoliehali na dátových vedcov, sledovali úspešnosť kampaní a uskutočňovali konkurenčné analýzy. Nástroje marketingovej analýzy zachytia a sledujú nasledujúce údaje týkajúce sa vašich marketingových kampaní:

- Údaje o návštevníkoch webových stránok
- Údaje o bode kontaktu / udalosti zákazníka
- Údaje o výkonnosti platenej kampane
- Údaje o nákupe zákazníka
- Údaje e-mailového marketingu

1.2.1. Nástroje založené na udalostiach

Tieto nástroje pomáhajú sledovať udalosti, konverzie a správanie našich používateľov.

MixPanel

Hlavným cieľom Mixpanelu je sledovať udalosti na webe, produkte alebo mobilnej aplikácii. MixPanel pomáha sledovať akcie, ktoré používatelia vykonávajú na našom webe alebo v mobilnej aplikácii (Android aj iOS). U udalostí, ktoré sme pridali na MixPanel, uvidíme počet, trendy, ktorí používatelia ich použili a v akom poradí.

Hlavnými funkciami MixPanelu sú lieviky, A / B testovanie rôznych variácií našej mobilnej aplikácie a sledovanie ich výsledkov, sledovanie jednotlivých používateľov podľa ich relácií a sledovanie trendov vybraných udalostí. MixPanel vyžaduje, aby sme definovali akcie, ktoré chceme sledovať a zamerať sa na ne. To je možné vykonať pridaním anotácií kódu alebo použitím vizuálneho selektora. Po výbere sa udalosti, ktoré chceme sledovať, pridajú na náš informačný panel s predstavenými metrikami podľa nášho výberu.

MixPanel bol postavený pre produktových manažérov, jeho vlastnosti sú preto viac produktovo orientované ako marketingové. Využívajú ho však aj marketingové tímy, najmä na identifikáciu správania používateľov a optimalizáciu lievikov.

Oribi

Oribi umožňuje každému robiť inteligentnejšie a rýchlejšie rozhodnutia založené na dátach. Vďaka jeho jednoduchému používateľskému rozhraniu a funkciám zameraným na výsledky je to jednoduché a nie sú potrebné nekonečné prehľady ani analytici. Oribi automaticky zhromažďuje 100% udalostí a konverzií na našom webe bez toho, aby ich bolo potrebné manuálne definovať alebo vykonávať zmeny kódu. Všetky zmeny na našom webe Oribi automaticky sleduje a zvýrazní ako novú udalosť spolu s akýmkoľvek trendom, zmenami vo výsledkoch alebo čímkoľvek, čomu musíte venovať pozornosť.

Oribi je v podstate pre každého obchodníka, ktorý sa chce zamerať na dosahovanie lepších marketingových výsledkov bez toho, aby sa spoliehal na vývojárov alebo analytikov.

1.2.2. Nástroje orientované na premávku

Tieto nástroje pomáhajú zamerať sa hlavne na meranie prenosu na našom webe a na to, odkiaľ pochádza.

Google Analytics

Základný, bezplatný a široko používaný nástroj na analýzu webových stránok spoločnosti Google. Google Analytics umožňuje sledovať prenos na našom webe, zistiť, odkiaľ naši návštevníci prichádzajú, ako boli na náš web presmerovaní, koľko času na ňom strávia a ďalšie. Okrem toho má služba Google Analytics aj integráciu so službou Google AdWords, ktorá pomáha analyzovať kampaň s hlbšími údajmi.

Google Analytics vyhovuje každému obchodníkovi, ktorý chce sledovať prenos, ktorý generuje jeho marketingové úsilie. Ak sa zameriavate hlavne na udalosti, konverzie, rast alebo predaj, Google Analytics vám nebude stačiť a pravdepodobne dosiahnete lepšie výsledky pomocou niektorého z vyššie uvedených nástrojov založených na udalostiach.

Základná verzia služby Google Analytics je zadarmo a obsahuje širokú škálu funkcií, ktoré vyhovujú väčšine spoločností. Pre veľké podniky existuje prémiová verzia, ktorá stojí okolo 100 000 dolárov ročne a umožňuje lepšie schopnosti analýzy dát s plnou podporou spoločnosti Google.

Hlavnou nevýhodou služby Google Analytics je zložitosť definovania a sledovania nových konverzií, ako aj možnosť sledovať jednotlivé relácie používateľov a porozumieť tomu, ako používatelia skutočne používajú náš web.

Piwik

Úplne bezplatná alternatíva otvoreného zdroja k službe Google Analytics. Piwik sleduje naše návštevy na webe a umožňuje nám vytvárať prispôbené prehľady, ktoré segmentujú údaje podľa zdroja návštevnosti, geografického umiestnenia používateľov, prehľadávačov a operačných systémov a čo je najdôležitejšie, ako používatelia interagovali s naším webom.

Piwik je nabitý mnohými funkciami vrátane cieľov sledovania úspešnosti našich marketingových kampaní, analýzy prekrytia stránok, zaznamenávania poznámok k analýze údajov a vlastných premenných.

Piwik sa môže hodiť pre jednotlivcov, malé podniky, veľké podniky a dokonca aj vlády za predpokladu, že postačia základné analytické schopnosti. Piwik je úplne zadarmo.

1.2.3. Analytické nástroje vyhľadávačov

Google

Vyhľadávacia konzola Google umožňuje analyzovať našu návštevnosť z organického vyhľadávania zo služieb Google. Vyhľadávacia konzola ukáže, ktoré hľadané výrazy nasmerujú používateľov na náš web po vyhľadaní v službe Google a po kliknutí na organický odkaz na váš web (čo znamená, že nejde o reklamu zo služby AdWords). Vyhľadávacia konzola v skutočnosti poskytuje viac informácií ako iba kliknutia. Môžeme tiež vidieť, koľko zobrazení mal každý hľadaný výraz a priemernú pozíciu, na ktorej prezentoval naše webové stránky ako výsledok vyhľadávania.

Vyhľadávacia konzola Google je skvelým nástrojom pre každého obchodníka, ktorý chce získať väčšiu návštevnosť z vyhľadávacích nástrojov, či už základných alebo platených. Údaje uvedené na vyhľadávacej konzole môžu byť obrovským pomocníkom pri dosahovaní tohto cieľa. Vyhľadávaciu konzolu Google je možné tiež integrovať do vášho účtu Google Analytics a zobrazovať ďalšie údaje.

Moz Pro

Moz Pro poskytuje údaje, ktoré môžu pomôcť zvýšiť prenos z vyhľadávacích nástrojov. Moz Pro poskytuje údaje o našom hodnotení a aj našich konkurentov vo výsledkoch vyhľadávania spolu s analýzou odkazov, hodnotením kľúčových slov a ich trendmi v čase.

Moz Pro je nástroj pre digitálnych marketingových pracovníkov a profesionálov v oblasti SEO, ktorých cieľom je zlepšovať výsledky zvyšovaním prenosu generovaného vyhľadaním. Moz Pro sa môže hodiť tak pre začiatočníkov, ako aj pre skúsených profesionálov.

1.2.4. Nástroje marketingových panelov

Tieto nástroje umožňujú agregovať údaje z rôznych marketingových kanálov a vytvoriť si vlastný jedinečný informačný panel.

Cyfe

Panel typu „všetko v jednom“, ktorý marketingovým pracovníkom umožňuje integrovať údaje z rôznych marketingových nástrojov, a umožňuje ich vidieť na jednom mieste.

S Cyfe môžeme sledovať údaje zo všetkých našich platform sociálnych médií, pay-per click marketingové kanály, predajné platformy a ďalšie. Pomocou vopred pripravených widgetov spoločnosti Cyfe je možné sa pripojiť k svojim účtom Google AdWords, Google Analytics alebo Salesforce a program zhromaždí všetky potrebné údaje z týchto nástrojov a zobrazí ich na jednom paneli.

Cyfe slúži každému obchodníkovi, ktorý pracuje s viacerými marketingovými kanálmi a rád vidí všetky základné údaje, ktoré potrebuje, na jednom mieste.

1.2.5. Nástroje vizuálneho správania

Pomocou týchto nástrojov je možné zistiť, ako sa používatelia správajú na našom webe pomocou tepelných máp.

Hotjar

HotJar má niekoľko efektívnych analytických funkcií, ako je analýza konverzného lievika, analýza registračných formulárov, prieskumy spätnej väzby a prieskumy, ale je známy predovšetkým ako nástroj tepelných máp.

Tepelné mapy HotJar pomáhajú pochopiť, ako návštevníci nášho webu interagujú s naším webom, aké sú ich posúvanie a kde klikajú. Ak napríklad nahráme novú vstupnú stránku a ešte nepoznáme jej výkon, pomocou HotJar ľahko pochopíme, ako s ňou interagujú používatelia, ktorí na ňu pristanú, kde budú zmätení a čo ich núti ku konverzii (alebo nekonvertovať).

Hotjar je veľmi vhodný pre nové alebo často sa meniace webové stránky. HotJar pomáha pochopiť silné a slabé stránky našich webových stránok.

1.2.6. A / B testovacie nástroje

Vytvorením viacerých variácií vykonáme A / B testy na zvýšenie počtu konverzií.

Optimizely

Optimizely umožňuje testovať rôzne variácie ľubovoľnej stránky alebo prvku na našom webe alebo produkte a merať ich výsledky, aby sme sa mohli rozhodnúť, ktorá variácia je najlepšia na dosiahnutie našich cieľov. Experimenty môžu byť textové alebo vizuálne a je možné úplne zmeniť vzhľad svojich stránok bez toho, aby sa v kóde vykonali akékoľvek zmeny.

Optimizely tiež ponúka integrácie s ďalšími analytickými nástrojmi vrátane Google Analytics, Bizble a Clicktale. Tieto integrácie umožňujú sledovať výsledky experimentov Optimizely na iných informačných paneloch spolu s ďalšou segmentáciou údajov.

Optimizely je užitočný nástroj pre obchodníka, ktorý sa stará o výkon svojich webových stránok a výsledky online marketingu. Optimalizačné schopnosti testovania A / B môžu ľahko povedať, ako lepšie prevádzať používateľov pozdĺž lievika predaja a nakoniec zvýšiť návratnosť investícií.

Každý z týchto nástrojov má svoje výhody a silné stránky. Zostáva len na vás, aby ste si vybrali správne nástroje marketingovej analýzy pre svoje potreby a prijali správne rozhodnutia založené na dátach, ktoré vám pomôžu pri vašom marketingovom úsilí.

1.3. Nové trendy analýzy dát

Namiesto sledovania krátkodobých cieľov, ako je znižovanie nákladov a zvyšovanie efektívnosti jednotlivých projektov, sa spoločnosti teraz sústreďujú na zastrešujúce, štandardizované a udržateľné oblasti analýzy.

1.3.1. Pokročilá analýza dát

Stratégie na zlepšenie tvorby poznatkov budú naďalej získavať na význame. Ako zástupný výraz pre nosiče vedomostí, ako je AI, strojové učenie a spracovanie prirodzeného jazyka, bude rozšírenej analýze údajov venovaná podstatne väčšia pozornosť v rámci inovačného úsilia aj pri implementácii existujúcich modelov. Namiesto „prepracovania“ veľkého množstva kvantitatívnych údajov môžu systémy na optimalizáciu rozhodovania využívať pokročilú analýzu údajov a návrhy generované umelou inteligenciou.

Predpokladá sa, že rozšírená analytika bude do roku 2021 tvoriť väčšinu predaja analytických riešení a riešení business inteligencie. Očakáva sa teda, že sa to stane bežnou charakteristikou procesov súvisiacich s údajmi. Tento trend môže viesť k ďalšiemu pokroku v pokročilej správe údajov.

1.3.2. Kontinuálna inteligencia

Kontinuálna inteligencia (KI) je návrhový vzor, v ktorom sú do obchodných operácií integrované analýzy v reálnom čase, ktoré spracúvajú súčasné a historické údaje na predpisovanie akcií v reakcii na obchodné momenty a iné udalosti.

Očakáva sa, že do roku 2022 bude viac ako 50% hlavných podnikových systémov bude KI implementovať. KI využíva kontextové údaje v reálnom čase na zlepšenie automatizovaného rozhodovania. I umožňuje generovanie nepretržitých, vysokofrekvenčných, intuitívnych znalostí zo všetkých údajov prostredníctvom integrácie analýz v reálnom čase do spoločnosti.

Pri spracovaní aktuálnych a historických údajov môže KI rýchlo reagovať na udalosti a ponúknuť normatívne riešenia. Nepretržitá inteligencia môže spoločnostiam pomôcť prijímať rozhodnutia v reálnom čase.

1.3.3. Digitálne dvojčatá

Spracovanie množstva prichádzajúcich údajov, najmä údajov o IoT (intelligence of things), sa stalo skutočnou výzvou pre spoločnosti, ktoré pracujú v kontexte tradičných riešení pre skladovanie dát alebo nástrojov business inteligencie. Aby bolo toto množstvo údajov použiteľné, musia byť údaje integrované do dátovej platformy s automatizovaným riešením integrácie údajov, ktoré zahŕňa čistenie údajov, ich historizáciu a správu verzií.

Podľa popredných IT výskumných spoločností bude do roku 2020 na celom svete odhadom 20 miliárd pripojených senzorov a koncových bodov. To znamená, že dovedy budú mať miliardy vecí svoje digitálne dvojčatá.

Digitálne dvojča je digitálna replika alebo reprezentácia „skutočnej“ jednotky. To sa generuje z údajov v reálnom čase zo senzorov a nachádza sa vo virtuálnom úložisku. Digitálne dvojčatá existujú v medzerách medzi našou fyzickou realitou a virtuálnou oblasťou a bezproblémový prenos dát umožňuje zlúčenie týchto dvoch svetov. Vďaka zdokonalenej schopnosti zhromažďovať a vizualizovať údaje a využívať analytiku na dosiahnutie obchodných cieľov sa očakáva, že digitálne dvojčatá sa budú v nasledujúcich rokoch vyvíjať.

1.3.4. Dátové rozprávanie údajov - Data Storytelling

Rozprávanie a vizualizácia údajov sú čoraz sofistikovanejšie, ale aj prístupnejšie, pretože spoločnosti presúvajú svoje dátové sklady do cloudu. S potrebou rozpoznávať vzorce a extrahovať hodnoty z údajov alebo kombinovať rôznorodé údaje s cieľom získať prehľad čelia organizácie aj výzve neustáleho generovania dátových príbehov, ktoré sú úplné, presvedčivé a kontextovo dobré.

Rôzne platformy pre cloudovú integráciu dát ponúkajú komplexné dátové riešenie, kde je vizualizácia dát okamžitá. Celostný prístup k údajom umožňuje rade nešpecializovaných zamestnancov prístup k údajom, získanie obchodných poznatkov a použitie týchto údajov na rozprávanie silných príbehov.

1.3.5. DataOps

Nový koncept, DataOps, zachytáva celý rad DevOps a agilných prístupov k cyklu analýzy údajov, od zachytávania údajov až po ich transformáciu a vykazovanie. Program DataOps je zameraný na vedcov v oblasti dát, dátových inžinierov a analytikov, ktorí chcú analyzovať údaje a vytvárať modely. Cieľom je dosiahnuť lepšiu kvalitu údajov a rýchlejšiu optimalizovanú analýzu.

S pribúdajúcimi prichádzajúcimi dátami nemusia byť klasické riešenia dátových skladov dostatočné. Do hry vstupuje potreba nepretržitej, automatizovanej a kvalitatívne konzistentnej integrácie údajov. DataOps monitoruje dátový tok pomocou štatistickej kontroly procesu, aby bola zaručená táto stála kvalita.

1.3.6. Hybridné nasadenie

Analýza veľkých dát generuje obrovské množstvo dát, ktoré je potrebné spracovať pre rozhodovanie. Mnoho spoločností skúma možnosti hybridných riešení, aby zvládli toto množstvo dát. Údaje sa ukladajú v lokálnych dátových centrách, zatiaľ čo cloud sa používa na analýzy alebo naopak. Spoločnosti už nemusia likvidovať svoj existujúci interný hardvér a softvér, len aby prešli na cloud. Môžu jednoducho optimálne využiť oba svety.

Ďalším trendom smerom k väčším spoločnostiam je využívanie čoraz diverzifikovanejších cloudových portfólií. To vedie k prosperujúcemu trhu s nástrojmi na správu cloudového portfólia. Tieto spoločnosti pomáhajú spoločnostiam sledovať rôzne cloudové služby a poskytovateľov.

1.4. Neurónové siete

Svet, tak ako ho vnímame je svet virtuálny, existujúci len v nasej mysli vo forme nervových vzruchov. Nevidíme elektromagnetické vlnenie v istom rozsahu frekvencií (predstavujúcim adekvátny podnet pre oko), “vidíme“ virtuálny svet vytvorený neurálnou aktivitou v zrakových centrách centrálného nervového systému.

Teória neurónových sietí vychádza z neurofyziologických poznatkov. Snazí sa vysvetliť správanie sa na princípe spracovania informácií v neurónových bunkách. Niekedy sa umelé neurónové siete označujú aj ako modely mozgu bez mysle, keďže sa snazia pochopiť nervový systém, ale nezoberajú sa psychikou².

Umelé neurónové siete sú modelované podľa ľudského mozgu a požívajú sa na strojové učenie a umelú inteligenciu. Na základe počítačov možno vyriešiť rôzne problémy, ktoré by boli pre nás takmer nemožné. Umelé neurónové siete sú algoritmy modelované z ľudského mozgu. Tento abstraktný model spojených umelých neurónov umožňuje pomocou počítačov riešiť zložité úlohy z oblasti štatistiky, informačných technológií a ekonomiky. Neurónové siete sú veľmi aktívnou oblasťou výskumu a považujú sa za základ umelej inteligencie.

Neurónové siete možno použiť na interpretáciu rôznych zdrojov údajov, ako sú obrázky, zvuky, texty, tabuľky alebo časové rady, a na extrahovanie informácií alebo vzorov s cieľom ich použitia na neznáme údaje. Týmto spôsobom je možné vytvárať predpovede založené na dátach pre budúcnosť. Umelé neurónové siete môžu mať rôznu úroveň zložitosti, ale v zásade majú štruktúru smerovaných grafov. Ak má umelá neurónová sieť obzvlášť hlboké sieťové štruktúry, nazýva sa to hlboké učenie.


1.4.1. Výstavba umelej neurónovej siete

Model neurónovej siete sa skladá z uzlov nazývaných tiež neuróny, ktoré prijímajú informácie od iných neurónov alebo zvonku, modifikujú ich a vydávajú na výstupe. To sa deje pomocou troch rôznych vrstiev, z ktorých každej je možné priradiť typ neurónu: tie pre vstup (vstupná vrstva), pre výstup (výstupná vrstva) a takzvané skryté neuróny (skryté vrstvy).

Informácie sú prijímané vstupnými neurónmi a výstupom z výstupných neurónov. Skryté neuróny ležia medzi nimi a zobrazujú interné informačné vzorce. Neuróny sú navzájom spojené takzvanými hranami. Čím silnejšie je spojenie, tým väčší je vplyv na druhý neurón.

² Vladimír Kvasnička, a kol. (04. 05 2020). Úvod do teórie neurónových sietí. Dostupné na Internete: http://www.2.fiit.stuba.sk/kvasnicka/Free%20books/Uvod%20do%20teorie%20neuronovych%20sieti_all.pdf

Obrázok. č.1: Príklad doprednej neurónovej siete s dvomi skrytými vrstvami



Zdroj: <https://umelainteligencia.sk/uvod-do-neuronovych-sieti/>, zverejnené 5. novembra 2019, Ing. Juraj Muráň

Vstupná vrstva

Vstupná vrstva dodáva neurónovej sieti potrebné informácie. Vstupné neuróny spracovávajú zadané údaje a váženým spôsobom ich prenášajú do ďalšej vrstvy.

Skrytá vrstva

Skrytá vrstva je medzi vstupnou vrstvou a výstupnou vrstvou. Zatiaľ čo vstupná a výstupná vrstva pozostáva iba z jednej úrovne, v skrytej vrstve môže byť ľubovoľný počet úrovní neurónov. Tu sa prijatá informácia znovu váži a odovzdáva z neurónu do neurónu na výstupnú vrstvu. K váženiu dochádza na každej úrovni skrytej vrstvy. Presné spracovanie informácií však nie je viditeľné. Preto pochádza aj skrytá vrstva. Zatiaľ čo prichádzajúce a odchádzajúce dáta sú viditeľné vo vstupnej a výstupnej vrstve, vnútorná oblasť neurónovej siete je v podstate čierna skrinka.

Výstupná vrstva

Výstupná vrstva je posledná vrstva a bezprostredne nadväzuje na poslednú vrstvu skrytej vrstvy. Výstupné neuróny obsahujú výsledné rozhodnutie, ktoré sa javí ako tok informácií.

1.4.2. Ako funguje umelá neurónová sieť

Hlboké učenie je hlavnou funkciou umelej neurónovej siete a funguje nasledovne: ak existuje sieťová štruktúra, každému neurónu sa priradí náhodná počiatočná váha. Potom sa vstupné údaje privedú do siete a každý neurón ich váži s ich individuálnou hmotnosťou. Výsledok tohto výpočtu sa preniesie do ďalších neurónov nasledujúcej vrstvy alebo do ďalšej vrstvy, hovorí sa tiež o „aktivácii neurónov“. Celkový výsledok sa počíta na výstupnej vrstve.

Samozrejme, ako pri každej metóde strojového učenia, nie všetky výsledky (výstupy) sú správne a vyskytujú sa chyby. Tieto chyby sú vypočítateľné, rovnako ako časť, ku ktorej jednotlivý neurón prispel k chybe. V ďalšom cykle učenia sa váha každého neurónu zmení tak, aby sa minimalizovala chyba. Potom nasleduje nový obeh, v ktorom prebehne nové meranie chyby a úpravy. Týmto spôsobom sa neurónová sieť zakaždým lepšie „naučí“ odvodiť známe výstupné údaje zo vstupných údajov.

Tento proces je veľmi podobný ľudskému rozhodovaciemu procesu. Spôsob, akým si ľudia myslia, je vnorený podobným spôsobom ako neurónová sieť.

1.4.3. Aplikácie umelých neurónových sietí

Kde sa teda takéto siete používajú? Možností je veľa. Spravidla sú predurčené pre tie oblasti, v ktorých je málo systematických znalostí, ale aby sa dosiahol konkrétny výsledok, musí sa spracovať veľké množstvo nepresných vstupných informácií (neštruktúrované údaje). Môže to byť napríklad v prípade rozpoznávania reči, rozpoznávania vzorov, rozpoznávania tváre alebo rozpoznávania obrázkov.

Ďalšie príklady použitia neurónových sietí:

Riadenie zložitých systémov

Autonómne šoférovanie

Systémy včasného varovania (vesmír, letectvo, obrana)

Zbraňové systémy
Porozumenie reči
Tlmočenie prirodzeného jazyka
Systémy odporúčaní v elektronickom obchode
Odhaľovanie podvodov
Rozpoznávanie obrázkov
Generovanie hlasov
Preklad jazyka
Predpovede počasia
Ekonomické systémy
Prognózy časových radov
Predpovedanie správania zákazníkov
Lekárske systémy (analýza chorôb)
Biometrické systémy a mnoho ďalších

Do nášho každodenného života už bolo integrovaných množstvo produktov a služieb založených na umelých neurónových sieťach. Spoločnosti ako Google, Facebook alebo Amazon sú dôležitými predstaviteľmi a považujú sa za priekopníkov vo vývoji a uplatňovaní hlbokého učenia a umelej inteligencie.

Neurónové siete sú základom umelej inteligencie a sú už schopné cieleným tréningom prevziať veľmi špecifické úlohy (slabá umelá inteligencia).

1.4.4. Typy umelých neurónových sietí

Existuje nespočetné množstvo architektúr neurónových sietí. Najdôležitejšie typy neurónových sietí sú:

Perceptron

Najjednoduchšia a najstaršia neurónová sieť. Zoberie vstupné parametre, pridá ich, použije aktivačnú funkciu a výsledok odošle na výstupnú vrstvu. Výsledok je binárny, to znamená buď 0 alebo 1, a teda porovnateľný s rozhodnutím áno alebo nie. Rozhodnutie sa robí porovnaním hodnoty aktivačnej funkcie s prahovou hodnotou. Ak je prahová hodnota prekročená, výsledku sa priradí 1, zatiaľ čo 0, ak sa prahová hodnota nedosiahne. Na základe toho boli vyvinuté ďalšie neurónové siete a aktivačné funkcie, ktoré tiež umožňujú prijímať viac výstupov s hodnotami od 0 do 1. Najznámejšia je funkcia sigmoidu, pri ktorej sa hovorí aj o sigmoidných neurónoch.

Dopredné neurónové siete

Pôvod týchto neurónových sietí siaha do 50. rokov 20. storočia. Vyznačujú sa tým, že vrstvy sú spojené iba s nasledujúcou vyššou vrstvou. Výcvikový proces doprednej neurónovej siete potom zvyčajne prebieha takto:

všetky uzly sú spojené

aktivácia prebieha od vstupnej do výstupnej vrstvy

aspoň jedna vrstva medzi vstupnou a výstupnou vrstvou

Ak je medzi vstupnou a výstupnou vrstvou obzvlášť veľký počet vrstiev, hovorí sa o neurónových sieťach s hlbokým posunom vpred “

Konvolučné neurónové siete

Skladacie neurónové siete alebo konvolučné neurónové siete (KNS) sú umelé neurónové siete, ktoré môžu obzvlášť efektívne pracovať so vstupnými údajmi 2D alebo 3D. Na detekciu objektov v obrazoch sa používajú najmä konvolučné neurónové siete.

Veľký rozdiel od klasických neurónových sietí spočíva v architektúre konvulčnej neurónovej siete, čo vysvetľuje názov „konvolúcia“ alebo „skladanie“. Skrytá vrstva v KNS je založená na postupnosti operácií skladania a združovania. Počas konvolúcie sa cez dáta tlačí takzvané jadro a počas tohto procesu sa počíta konvolúcia, ktorá je porovnateľná s

násobením. Neuróny sú aktualizované. Následné zavedenie združovacej vrstvy zabezpečí, že sa výsledky zjednodušia. Potom sa zachovajú iba dôležité informácie.

To tiež zaisťuje, že vstupné údaje 2D alebo 3D sa zmenšia. Ak to bude pokračovať, na konci bude vo výstupnej vrstve vektor, „úplne spojená vrstva“. To má osobitný význam, najmä pri klasifikácii, pretože obsahuje toľko neurónov, koľko je tried, a pomocou pravdepodobnosti hodnotí príslušné priradenie.

Rekurentné neurónové siete

Rekurentné neurónové siete (RNS) pridávajú do umelej neurónovej siete opakujúce sa bunky, čo dáva neurónovým sieťam pamäť. Prvou umelou neurónovou sieťou tohto druhu bola Jordánska sieť, v ktorej každá skrytá bunka prijímala svoj vlastný výstup s pevným oneskorením - jednou alebo viacerými iteráciami. Inak je to porovnateľné s klasickými doprednými sieťami.

Samozrejme existuje veľa variácií - napríklad prechod stavu na vstupné uzly, variabilné oneskorenia atď., ale základná myšlienka zostáva rovnaká. Tento typ neurónovej siete sa používa najmä vtedy, keď je dôležitý kontext. Pretože potom rozhodnutia z minulých iterácií alebo vzoriek významne ovplyvňujú tie súčasné. RNS majú rozhodujúcu nevýhodu v tom, že sa časom stanú nestabilnými. Preto je dnes bežnou praxou používať takzvané jednotky dlhodobej krátkodobej pamäte. Tieto tiež stabilizujú RNS pre závislosti, ktoré existujú počas dlhšieho časového obdobia. Najbežnejším príkladom takýchto vzťahov je textové spracovanie - slovo je možné analyzovať iba v spojení s predchádzajúcimi slovami alebo vetami. Ďalším príkladom je spracovanie videí, napríklad pri autonómnom riadení. Objekty v obrazových sekvenciách sú rozpoznávané a sledované v priebehu času.

1.5. Deep learning

Hlboké učenie sa vyvíjalo ruka v ruke s digitálnou érou, ktorá priniesla explóziu dát vo všetkých formách a zo všetkých oblastí sveta. Tieto údaje, známe jednoducho ako veľké dáta, sú čerpané okrem iného zo zdrojov ako sociálne médiá, internetové vyhľadávače, platformy elektronického obchodu. Avšak údaje, ktoré sú zvyčajne neštruktúrované, sú také

obrovské, že môže trvať desaťročia, kým ich ľudia pochopia a získajú z nich príslušné informácie. Spoločnosti si uvedomujú neuveriteľný potenciál, ktorý môže vyplynúť z odhalenia tohto množstva informácií, a čoraz viac sa prispôbujú systémom AI pre automatizovanú podporu.

Umelá neurónová sieť sa učí podobným spôsobom ako človek. To znie nielen zložito, ale aj trochu ako sci-fi. Ale takzvané hlboké učenie, podoblasť umelej inteligencie (AI), sa v priemyselnej výrobe už dávno stala realitou a stále viac sa tam využíva.

Rozpoznanie, kontrola alebo klasifikácia objektov a funkcií bola často možná iba pri zložitom programovaní, ba až technicky nemožná. Vďaka hlbokému učeniu je teraz umožnené to robiť jednoduchšie. Táto technológia je založená na viacvrstvových umelých neurónových sieťach.

1.6. Definícia hlbokého učenia

Hlboké učenie je podoblasťou strojového učenia a využíva neurónové siete a veľké objemy dát. Metódy učenia sú založené na fungovaní ľudského mozgu a vedú k schopnosti robiť si vlastné prognózy alebo rozhodnutia. Takzvané hlboké učenie je špeciálna metóda spracovania informácií. Na vytvorenie umelej inteligencie sa používajú tréningové metódy, ktoré využívajú a analyzujú veľké množstvo dát. Spôsob jeho fungovania je v mnohých oblastiach inšpirovaný učením v ľudskom mozgu. Na základe existujúcich informácií a neurónovej siete môže systém opakovane spájať naučené s novým obsahom a tak sa učiť znova. Vďaka tomu je stroj schopný robiť prognózy alebo rozhodnutia a spochybňovať ich. Rozhodnutia sú potvrdené alebo zmenené pri novom pokuse. Ľudia spravidla už nezasahujú do skutočného procesu učenia.

Hlboké učenie je obzvlášť vhodné pre všetky aplikácie, v ktorých je k dispozícii veľké množstvo údajov, z ktorých je možné odvodiť vzory a modely. Umelé neurónové siete, ktoré sú opakovane prepojené počas procesu učenia, slúžia ako technický základ pre hlboké učenie.

1.6.1. Základný koncept hlbokého učenia

Hlboké učenie učí stroje učiť sa. Stroj je schopný zlepšovať svoje schopnosti nezávisle a bez ľudského zásahu. To sa dosiahne extrakciou a klasifikáciou vzorov z existujúcich údajov a informácií. Získané vedomosti môžu byť následne korelované s údajmi a prepojené v ďalšom kontexte. Nakoniec je stroj schopný robiť rozhodnutia na základe odkazov.

Neustálym spochybňovaním rozhodnutí majú informačné odkazy určitú váhu. Ak sa rozhodnutia potvrdia, ich váha sa zvyšuje; ak sa revidujú, váha sa zníži. Medzi vstupnou vrstvou a výstupnou vrstvou sa vytvára čoraz viac úrovní medzivrstiev a odkazov. Skutočný výstup určuje počet medzivrstiev a ich väzba.

Hlboké učenie dosahuje vyššiu úroveň presného rozpoznávania ako kedykoľvek predtým. Vďaka nedávnym pokrokom je hlboké učenie teraz také pokročilé, že zvládne niektoré úlohy lepšie ako ľudia, napríklad klasifikáciu objektov v obrázkoch.

1.6.2. Ako funguje hlboké učenie

Väčšina metód hlbokého učenia využíva architektúry vo forme neurónových sietí. Preto sa modely hlbokého učenia často označujú ako hlboké neurónové siete.

Termín „hlboký“ sa všeobecne vzťahuje na počet skrytých vrstiev v neurónovej sieti. Bežné neurónové siete obsahujú iba 2 až 3 skryté vrstvy, zatiaľ čo hlboké siete obsahujú až 150 vrstiev.

Modely hlbokého učenia sa trénujú pomocou veľkých súborov klasifikovaných údajov a architektúr neurónových sietí, ktoré sa učia funkcie priamo z údajov bez potreby manuálneho získavania funkcií. Jeden z najpopulárnejších typov hlbokých neurónových sietí je známy ako konvolučné neurónové siete (KNS). KNS konvertuje naučené funkcie so vstupnými dátami pomocou 2D konvolučných rovín, vďaka ktorým je táto architektúra vhodná na spracovanie 2D údajov, ako sú obrázky.

KNS eliminujú potrebu manuálnej extrakcie funkcií. Takže netreba identifikovať prvky, ktoré sa používajú na klasifikáciu obrázkov. KNS funguje tak, že extrahuje funkcie priamo z obrázkov. Relevantné funkcie nie sú vopred vyškolené, naučia sa ich, zatiaľ čo sa sieť

trénuje na množine obrázkov. Vďaka tejto automatizovanej extrakcii funkcií sú modely hlbokého učenia ideálne vhodné pre úlohy počítačového videnia, ako je klasifikácia objektov.

KNS sa učia od desiatok alebo stoviek skrytých vrstiev rozpoznávať rôzne vlastnosti obrázka. Každá skrytá úroveň zvyšuje zložitosť naučených obrazových funkcií. Napríklad prvá skrytá vrstva by sa mohla naučiť rozpoznávať obrysy a posledná sa naučiť rozpoznávať zložitejšie tvary, ktoré sú špecifické pre tvar rozpoznávaného objektu.

1.6.3. Rozdiel medzi strojovým učením a hlbokým učením

Hlboké učenie je špecializovaná forma strojového učenia. Pracovný postup strojového učenia začína manuálnym extrahovaním relevantných funkcií z obrázkov. Potom sa na základe charakteristík vytvorí model, ktorý kategorizuje objekty na obrázku. V pracovnom postupe hlbokého učenia sa príslušné funkcie automaticky extrahujú z obrázkov. Okrem toho sa v rámci hlbokého učenia uskutočňuje „proces úplného učenia“. Sieť prijíma nespracované údaje a úlohu, napríklad klasifikáciu, a učí sa túto úlohu vykonávať automaticky. Ďalším dôležitým rozdielom je, že algoritmy hlbokého učenia sú škálované podľa údajov, zatiaľ čo procesy učenia sa zbiehajú s plochými sieťami. Metódy strojového učenia, ktoré dosahujú plató na určitej úrovni výkonu, keď poskytujú siete ďalšie príklady a údaje o tréningu, sa označujú ako „ploché“. Dôležitou výhodou sietí hlbokého učenia je, že ich výsledky sa často neustále zlepšujú, keď sa zvyšuje objem dát.

1.6.4. Príklad hlbokého učenia

Aplikácia na rozpoznávanie obrázkov sa môže naučiť, ako mačka vyzerá. Systém strojového učenia na tento účel prijíma veľké množstvo obrázkov. Vysoký výpočtový výkon je potrebný na následnú analýzu a vyhodnotenie každého jednotlivého obrazu.

Prvá zobrazovacia vrstva môže abstrahovať jednotlivé pixely obrázka mačky a potom kódovať obrysy alebo hrany. V druhej vrstve neurónovej siete sú rôzne usporiadania okrajov spojené a kódované. Tretia vrstva mohla kódovať prvky ako mačací nos a oči skôr, ako štvrtá

vrstva rozpozná, že obrázok zobrazuje mačaciu tvár. Výsledkom je, že model priradí obrázok k kategórii mačiek alebo mačiek.

Zvláštnosťou hlbokého učenia sú samooptimalizačné procesy. Bez predchádzajúcich znalostí programovaných odborníkmi sa systémy dozvedia, ktoré funkcie sa najúčinnšie transformujú zo vstupných údajov na ktorej úrovni. To má výhodu v tom, že ľudia nemusia zasahovať. Na druhej strane nie je vždy jasné, čo sa systém učí. Modely hlbokého učenia sa preto považujú aj za čiernu skrinku.

1.6.5. Aplikácia hlbokého učenia

Bežnými prípadmi použitia hlbokého učenia sú rozpoznávanie obrazu a reči, prediktívna analýza, systémy odporúčaní alebo detekcia anomálií.

„Tento obrázok ukazuje nevhodný obsah“, „Táto finančná transakcia je podvodom“ alebo „Tento e-mail je spam!“ Sú užitočné vyhlásenia založené na klasifikácii založenej na hlbokom učení.

Zoskupenie údajov umožňuje výsledky ako „Používateľ veľmi pravdepodobne hľadá tento dokument“ alebo „Tieto dva zvuky sú podobné“. Tento príklad je jedným z predpokladov identifikácie zvukových klipov vo väčších zvukových súboroch a prepisu hovoreného slova ako textu.

Tieto procesy hlbokého učenia sa používajú v každodenných službách, ako napríklad hlasové ovládanie Alexa, označovanie obrázkov na Facebooku alebo automatický preklad DeepL.

1.6.6. Oblasť využitia pre hlboké učenie

Hlboké učenie sa hodí všade tam, kde je možné preskúmať veľké objemy dát kvôli vzorom a modelom. Hlboké učenie sa preto často používa v súvislosti s umelou inteligenciou na rozpoznávanie tváre, predmetu alebo reči. Napríklad s rozpoznávaním reči je vďaka hlbokému učeniu možné, aby si systémy nezávisle rozširovali slovnú zásobu o nové slová

alebo frázy. Znáмым príkladom takéhoto spôsobu práce je inteligentný hlasový asistent Siri od spoločnosti Apple. Ďalšími oblasťami použitia sú preklad hovorených textov, pokročilá umelá inteligencia v počítačových hrách, autonómne riadenie alebo predikcia správania zákazníka na základe údajov z CRM systému.

1.7. Prediktívny marketing

Prediktívny marketing je marketingová technika, ktorá spočíva v použití dátovej analýzy na určenie, ktoré marketingové stratégie a akcie majú najvyššiu pravdepodobnosť úspechu. Má svoje miesto v prostredí marketingových technológií, pretože spoločnosti využívajú všeobecné obchodné údaje, údaje o marketingových a predajných aktivitách a matematické algoritmy na porovnávanie vzorov a určovanie kritérií, ktoré sú pre ich ďalšie marketingové akcie najvhodnejšie. Spoločnosti, ktoré využívajú túto stratégiu, sa usilujú prijímať rozhodnutia založené na dátach, aby priniesli lepšie výsledky.

V dnešnom technologicky vyspelom svete nie je predpovedanie ďalších krokov zákazníkov pre značky už žiadnou novou taktikou. Bolo by skvelé vedieť, ktoré zoznamy kontaktov sa oplatí kúpiť, skôr ako si ich kúpite alebo urýchlite obchodné cykly tým, že obchodným zástupcom umožníte pracovať efektívne a produktívnejšie. Prediktívny marketing rastie na popularite, podmienky nikde neboli priaznivejšie ako sú teraz.

1.7.1. Definícia predikcie

Predikcia je proces vyplňovania chýbajúcich informácií. Predikcia berie informácie, ktoré máme, často nazývané „dátá“, a pomocou nich generuje informácie, ktoré nemáme. Veľa diskusií o AI zdôrazňuje rozmanitosť predikčných techník využívajúcich čoraz nejasnejšie názvy a označenia: klasifikácia, zhlukovanie, regresia, rozhodovacie stromy, Bayesov odhad, neurónové siete, analýza topologických údajov, hlboké učenie atď.

1.7.2. Definícia prediktívneho marketingu

Prediktívny marketing je strategické využitie existujúcich údajov o zákazníkoch na identifikáciu vzorcov a predikciu správania zákazníkov, marketingových výsledkov a predajných trendov, okrem iného, v budúcnosti. Využíva prediktívne analýzy na určenie marketingových stratégií a akcií, pri ktorých bude najväčšia pravdepodobnosť úspechu alebo neúspechu.

Aj keď zhromažďovanie údajov o zákazníkoch na podporu marketingových snáh nie je žiadnou novou praxou, moderné stratégie využívajú strojové učenie a algoritmy umelej inteligencie (AI), ktoré poskytujú veľké objemy informácií. Obchodníci môžu tieto agregované databázy profilov zákazníkov využiť na vývoj prediktívnych modelov, analýzu výkonu programu a obohatenie potenciálnych zákazníkov.

1.7.3. Dôležitosť prediktívneho marketingu na trhu

Ak majú kupujúci a spotrebitelia v podnikaní jednu vec spoločnú, je to vysoký počet možností, ktoré majú na trhu k dispozícii. Obchodníci môžu využívať prediktívnu dátovú vedu na všetkých kanáloch, čo im dáva viac príležitostí dať správu na mieru pred zainteresovaným publikom. Prediktívne technológie sa integrujú do e-mailových, sociálnych, webových a telefónnych kanálov a umožňujú tak optimálne nasadenie strategických správ.

Prediktívne modelovanie sa čoraz viac stáva nevyhnutnou súčasťou automatizácie marketingu. Algoritmy je možné upravovať v reálnom čase a poskytovať tak aktuálne rady pre už prebiehajúce marketingové kampane. Prediktívne modely konkrétne podporujú marketingových pracovníkov zlepšovaním generovania a predaja potenciálnych zákazníkov, čo sú niektoré z najdôležitejších cieľov marketingových pracovníkov B2B. Prediktívne nástroje môžu navyše pomôcť marketingovým pracovníkom určiť, ktoré publikum potrebuje špeciálny obsah - napríklad elektronickú knihu alebo dokument - na ďalšie ciele, ako je povedomie o značke a vzdelávanie publika.

1.7.4. Vzostup prediktívneho marketingu

Prediktívny marketing umožňuje spoločnostiam získať viac informácií o svojich existujúcich zákazníkoch s cieľom identifikovať vzorce predvídania budúcich výsledkov a trendov. Nejde o novú prax, ale je oveľa zvládnuiteľnejšia než predchádzajúca, ktorá si vyžadovala týždne alebo mesiace používania nástrojov na extrakciu, transformáciu a načítanie, na zhromažďovanie údajov z rôznych zdrojov. Vybudovať jediný zdroj na analýzu a hodnotenie prieskumu na základe podobnosti so skutočnými zákazníkmi.

K rozmachu prediktívneho marketingu viedli tri hlavné faktory, medzi ktoré patrí obrovské množstvo dát, ku ktorým majú obchodníci prístup zo všetkých dostupných zdrojov, prístup k dátam v reálnom čase a zavedenie cloud computingu, ktorý poskytuje technológie Big Data. Teraz, keď sú nástroje marketingových technológií presnejšie a prepracovanejšie, majú marketingoví pracovníci prístup k lepším výsledkom a môžu merať zdroje reklamy a publika a vytvárať kampane s predvídateľnými odpoveďami. Keď budú nástroje marketingových technológií dostupnejšie a spoločnosti začnú vnímať hodnotu tohto prístupu založeného na dátach, dôjde k posunu smerom k prijatiu tejto techniky.

Keď bude predikcia lacná, bude k dispozícii viac predikcií a ďalšie doplnky. Tieto dve jednoduché ekonomické sily poháňajú nové príležitosti, ktoré predikčné stroje vytvárajú. Na nízkych úrovniach môže predikčný prístroj zbaviť ľudí prediktívnych úloh a tak ušetriť na nákladoch. Ale v určitom okamihu sa predikčný stroj môže stať taký presný a spoľahlivý, že zmení spôsob, akým organizácia robí veci. Niektoré AI ovplyvnia ekonomiku podniku tak dramaticky, že sa už nebudú používať na jednoduché zvýšenie produktivity pri vykonávaní stratégie: zmenia samotnú stratégiu

1.7.5. Ako funguje prediktívny marketing

Prediktívny marketing využíva dátovú vedu na zhromažďovanie veľkého množstva informácií a prediktívne analýzy, ktoré vedú marketingových pracovníkov k najlepším možným marketingovým akciám pre ich značku.

Prediktívne technológie dokážu identifikovať zoznamy kontaktov, ktoré sa oplatí kúpiť, na základe porovnania týchto kontaktov a údajov o zákazníkoch, ktoré už organizácia vlastní.

Analytické nástroje môžu podobne pomôcť rozšíriť existujúcich potenciálnych zákazníkov značky pomocou údajov a služieb obohacovania. Kombinácia týchto riešení dáva obchodným zástupcom schopnosť viesť rozhovory s vedúcimi, ktoré sú produktívnejšie a vyžadujú kratší čas na budovanie vzťahov.

Ak sú prediktívne marketingové modely implementované správne, môžu byť prospešné pre každú fázu nákupného procesu. Predpovede počasia interagujú so spoločnosťou prostredníctvom informačných bulletinov, vstupných stránok, správ, telefonických hovorov alebo chatbotov. Prediktívne riešenia okrem iného poskytujú podporu interakcie na mieru pre každú fázu.

1.7.6. Typy riešení prediktívneho marketingu

Najpoužívanejšie prediktívne marketingové riešenia sú:

Prediktívne webové odporúčania

Keď zákazníci navštívia webové stránky, prediktívna analýza prispôsobí zobrazenia, komunikáciu a výzvy na akciu tak, aby vytvorili neuveriteľne osobný zážitok z nakupovania. Môže to zahŕňať pridanie priestoru k produktom „často kupované spoločne“, panelom odporúčaní alebo odporúčaným produktom, na ktoré by sa títo návštevníci mohli obrátiť.

Prediktívne mobilné odporúčania

Pokročilé prediktívne marketingové riešenia sú vyvíjané s ohľadom na mobilných používateľov. Veľké množstvo online nakupovania sa realizuje prostredníctvom mobilných zariadení, takže je nevyhnutné vyhodnotiť prediktívne technológie s cieľom presného poskytovania prediktívnych informácií a odporúčaní prostredníctvom prehliadačov a mobilných aplikácií.

Prediktívne e-mailové odporúčania

Poskytovanie cielených e-mailových odporúčaní zákazníkovi je možné pomocou prediktívnych riešení, okrem iných faktorov aj analýzou ich histórie nakupovania a miery

zapojenia. Medzi e-maily s odporúčaním patria okrem iného kampane po zakúpení, kampane opusteného prehliadania a kampane opusteného nákupného košíka.

1.7.7. Výhody prediktívneho marketingu

Pretože nástroje založené na dátach sú čoraz dostupnejšie pre obchodníkov, eliminovali potrebu vedcov zaoberajúcich sa dátami interpretovať dáta. Tieto nástroje pomáhajú spoločnostiam používať ich údaje na predpovedanie toho, ako zákazníci nakupujú pri nákupe a koľko minú; to všetko je založené na ich minulom správaní. S vývojom týchto nástrojov môžu značky používať automatizované marketingové systémy, ktoré využívajú skóre, modely a získavajú prehľady v reálnom čase.

Medzi niektoré výhody spracovania prehľadu vyhľadávania o zákazníkoch a ich správaní patrí zvýšenie výnosov, lepšie zapojenie zákazníkov, sofistikovaná segmentácia údajov, zlepšenie bodovania potenciálnych zákazníkov, identifikácia kampaní a lepšie využitie marketingových rozpočtov. Prediktívny marketing odstraňuje dohady marketingových spoločností so schopnosťou vykonávať presné predpovede.

1.7.8. Prediktívne marketingové výzvy

Jednou z najbežnejších a naj frustrujúcejších výziev prediktívneho marketingu je to, že niekedy nemusí zodpovedať očakávaniam plne automatizovaných analytických očakávaní od vedúcich pracovníkov a marketingových pracovníkov značky. To ukazuje, že počítačom stále chýba v porovnaní s ľuďmi, ktorí majú lepšiu intuíciu a vysoko syntetizované rozpoznávanie.

Oneskorené vykazovanie a rôzne prehľady fungujú ako prekážky, ktoré bránia prístupu ku kritickým poznatkom a pre efektívnejšie vynakladanie zdrojov v obchodných a marketingových oddeleniach. Ľudia syntetizujú informácie s praktickými ľudskými skúsenosťami spôsobmi, ktoré by nikdy nemohli byť vložené do kódu alebo dokonca pochopené počítačom. Príprava počítačov a strojov na predvídanie možných scenárov je stále výzvou a až do jej prekonania ľudia vždy vyhrajú tento závod s technológiou.

1.7.9. Príklady použitia prediktívneho marketingu

Bez ohľadu na marketingové ciele spoločnosti by riešenie prediktívneho modelovania mohlo zvýšiť šance na úspech. Tu je niekoľko prípadov použitia na lepšie pochopenie prediktívneho marketingu:

Predvídať správanie zákazníka

Pre tento prípad použitia si vezmeme príklad Amazonu. Keď spoločnosť Amazon navrhuje nové produkty pre spotrebiteľa, platforma sa snaží predvídať správanie. Napríklad, ak si niekto kúpi mobilný telefón, Amazon s najväčšou pravdepodobnosťou odporučí okrem iných súvisiacich produktov aj kryt na mobilný telefón alebo kompatibilné záložné zdroje. Podobne tieto algoritmy poskytujú návrhy aj v priestore B2B.

Znižovanie fluktuácie zákazníkov

Riešenia prediktívneho modelovania poskytujú marketingovým pracovníkom schopnosť predvídať zákazníkov, ktorí sa chystajú zmeniť svoje podnikanie. To umožňuje týmto marketingovým pracovníkom vyhľadávať zákazníkov, zlepšovať procesy alebo poskytovať kompenzácie za udržanie zákazníkov skôr, ako bude neskoro. Prediktívna analýza dokáže zvýrazniť najpravdepodobnejšie zmeny zákazníkov, a tým poskytuje značkám možnosť konať a minimalizovať opotrebenie s cieľom zvýšiť hodnotu životnosti zákazníka.

Cielená kvalifikácia potenciálneho zákazníka

Pre spoločnosť, ktorá vlastní súbor historických údajov, ktoré popisujú všetkých jej klientov v jej databáze a ich nákupné návyky, je možné použiť prediktívny algoritmus na porovnanie správania s inou informačnou sadou s cieľom presne určiť potenciálne podobnosti poézie s predchádzajúcimi úspešnými konverziami značky. To podporuje obchodných zástupcov a umožňuje im uprednostňovať potenciálnych zákazníkov, u ktorých je vyššia pravdepodobnosť konania.

1.7.10. Využitie technológie prediktívneho marketingu

Prediktívna technológia poskytuje obchodníkom potrebné nástroje, aby sa mohli ponoriť do personalizácie a byť súčasťou marketingu novej generácie a zapojenia spotrebiteľov. Vďaka prediktívnej technológii môžu obchodníci dosiahnuť nasledujúce ciele:

Zvýšenie výnosov a návratnosť investícií do marketingu

Pretože spotrebiteľia s väčšou pravdepodobnosťou reagujú na personalizovaný a personalizovaný obsah a obsah šitý na mieru podľa ich nákupných preferencií, obchodníci používajú prediktívne technológie na premenu minulých nákupných trendov na budúce nákupné skúsenosti.

Pozitívne skúsenosti zákazníkov

Prediktívne riešenia fungujú na veľkom objeme zákazníckych údajov, čo ovplyvňuje marketingové stratégie, ako sú automatizačné riešenia, podrobné správy a prehľady. Zákazníci s potešením poskytujú ďalšie osobné údaje pre nakupovanie, ktoré sú viac prispôsobené ich preferenciám.

Vytváranie omni-kanálových výprav zákazníkov

Prediktívna analýza kombinuje web, mobil a e-mail a vytvára konzistentné nákupné zážitky, a to v závislosti na kanáli alebo platforme, ktorú si zákazníci vyberú.

Vytváranie lojalistov značiek

Keď marketingové oddelenia spoločnosti kladú veľký dôraz na vytváranie personalizovaných marketingových skúseností (aby sa s každým zákazníkom zaobchádzalo ako s jednotlivcom), sú obdarovaní opakovanými zákazníkmi, ktorí sú spokojní so získanou skúsenosťou.

1.8. Umelá inteligencia v marketingu

Umelá inteligencia sa dá efektívne využiť v marketingu pomocou jednoduchých metód. Pre spoločnosti ponúka obrovský optimalizačný potenciál, najmä v marketingu. Týmto spôsobom je možné zvýšiť mieru objednávok, predvídať správanie zákazníkov a vysielat' prispôsobenú reklamu. Umelá inteligencia sa v marketingu úspešne využíva už roky, ale zároveň veľa spoločností s využívaním umelej inteligencie iba začína.

Umelá inteligencia v marketingu znamená použitie algoritmov na hľadanie zaujímavých vzorov a vzťahov v existujúcich údajoch o zákazníkoch, aby sa dosiahli predpovede o budúcom správaní a nákupnom rozhodovaní zákazníkov. Tieto predpovede a odporúčania možno potom cielene použiť na generovanie väčšieho predaja pomocou personalizácie a tiež na zníženie nákladov cielenou kontrolou marketingových aktivít. Oblasť využitia umelej inteligencie v marketingu sú rozmanité a siahajú od optimalizácie cien pomocou chatbotov až po postupy zabraňujúce stratu resp. odchod zákazníkov.

Výhody umelej inteligencie je možné dosiahnuť nielen v rámci marketingových kanálov. Metódy umelej inteligencie možno tiež použiť v e-mailovom marketingu alebo na webe vo webových obchodoch na prispôsobenie "cesty zákazníka". Marketing zameraný na zákazníka môže tiež viesť k zvýšeniu predaja a zlepšeniu lojality zákazníkov. Často sa používajú takzvané odporúčacie systémy, ktoré generujú správne ponuky produktov pre e-mailové kampane alebo sa zobrazujú na webe vo webovom obchode.

1.8.1. Príklady aplikácií umelej inteligencie v marketingu

Umelá inteligencia sa používa v marketingu na rôzne úlohy s cieľom optimalizovať marketingové procesy, prispôbiť zacielenie potrebám zákazníkov a ponúknuť správnu ponuku v pravý čas. V ďalšom sa budem venovať jednotlivým aplikačným príkladom umelej inteligencie v marketingu.

Prognózovanie celoživotnej hodnoty zákazníka

Celoživotná hodnota zákazníka (CHZ) je veľmi známy pojem v marketingovom manažmente. CHZ zahŕňa hodnotenie zákazníkov podľa ich ziskovosti a voľného

potenciálu. Pre dobrú CHZ je potrebné robiť prognózy pre budúcnosť, ktoré sú založené na strojovom učení a sú súčasťou umelej inteligencie. Dobre vymodelovaná CHZ dokáže veľmi presne predpovedať, ako sa bude zákazník vyvíjať v priebehu nasledujúcich 12 mesiacov. Marketingové rozpočty a kampane je potom možné naplánovať oveľa presnejšie.

Niektoré spoločnosti idú o krok ďalej a vypočítajú CHZ alebo prognózu predaja pre každú kombináciu skupiny zákazníkov a produktov. Týmto spôsobom možno identifikovať a využiť potenciály krížového predaja a nadpredaja v určitých skupinách výrobkov.

Hodnota zákazníka odpovedá na nasledujúce otázky:

- *Aký veľký potenciál má zákazník v budúcom roku?*
- *Aký predaj sa očakáva od zákazníka v budúcnosti?*
- *Aký marketingový rozpočet by sa mal minúť na zákazníka?*
- *Existujú zákazníci, ktorí nie sú ziskoví a majú malý potenciál?*

Celoživotná hodnota zákazníka sa skladá z týchto komponentov:

- Príspevková marža (a prognóza budúceho predaja)
- Miera aktivity alebo miera zadržania
- Obstarávacie náklady

Hodnota zákazníka založená na strojovej predikcii je veľmi užitočným prvkom marketingovej kontroly. Každému zákazníkovi je pridelená určitá hodnota, podľa ktorej sú potom marketingové aktivity individuálne kontrolované.

Predchádzanie odchodu zákazníkov prostredníctvom umelej inteligencie

Zistenie odchodu zákazníkov v ranom štádiu je obzvlášť dôležité pre obchodné modely založené na zmluvách a predplatných. Získavanie nových zákazníkov je zvyčajne veľmi nákladné, a preto sú tieto obchodné modely často ziskové iba vtedy, ak je ich životnosť vysoká. Toto sa dosahuje dlhodobými vzťahmi so zákazníkmi. Predikcia churn zákazníkov,

teda zákazníkov, ktorí by mohli odísť, je zaujímavým prípadom použitia umelej inteligencie v marketingu.

Umelá inteligencia tu môže byť užitočná pre tieto dva prípady použitia:

- Odchod zákazníkov
- Znovuzískanie zákazníkov

Predpovedanie odchodu zákazníkov

V podstate sa jedná o snahu zamedziť výpovediam na základe strojového učenia a výsledných vzorcov z minulého správania. Na základe týchto vzorcov a vzťahov sa aktívnym zákazníkom potom priradí pravdepodobnosť odchodu.

Zákazníkom s vysokou pravdepodobnosťou odchodu, teda ukončenia zákazníckeho vzťahu, je preventívne poskytnutá atraktívna ponuka. Týmto spôsobom je možné ich dlhodobo viazať. Toto je bežný prípad použitia umelej inteligencie, najmä v zmluvnom obchode, ako sú telekomunikácie, poisťovníctvo, banky atď.

Samozrejme, existujú aj obchodné modely, ktoré majú tendenciu byť krátkodobejšie, napríklad služby, ktoré je možné zrušiť na mesačnej báze alebo predplatené služby. Podobným postupom sa dá tiež urobiť predpoveď.

Predikcia znovuzískania zákazníkov

Znovuzískanie zákazníkov, ktorá je často spojené s vysokými nákladmi, môže byť tiež podporené umelou inteligenciou:

- *Koho aktívne kontaktovať v súvislosti s opatreniami na znovuzískanie?*
- *Ktorému zákazníkovi poslať e-mail, aby sa mohla obnoviť zmluva?*
- *Aká zľava vedie k predĺženiu zmluvy?*

Odpovede na tieto otázky sú vďaka umelej inteligencii podložené dátami a presné. Na základe toho je možné efektívne koordinovať znovuzískavanie zákazníkov.

Optimalizácia cien pomocou umelej inteligencie

Dnes je úplne bežné, že ceny produktov na Amazone sa upravujú podľa dopytu alebo sa ceny na veľkých hotelových portáloch menia v priebehu niekoľkých minút. Je za tým umelá inteligencia, ktorá upravuje ceny nielen na základe času, ale aj individuálne na základe ochoty používateľa platiť.

Základom pre individuálne stanovenie cien je veľké množstvo dát, ktoré sa ukladajú v systémoch veľkých dát a používajú sa ako ovplyvňujúce faktory pri analýze. Okrem informácií o vývoji cien a jednotlivých produktoch sú súčasťou metódy strojového učenia aj charakteristiky špecifické pre zákazníka (napríklad história nákupu, vek, umiestnenie atď.).

Na základe týchto charakteristík sa analyzuje a predpovedá akceptácia ceny každého zákazníka, čo vedie k optimalizácii pravdepodobnosti predaja.

Predikcia nákupného správania pre marketingové kampane

Mnoho spoločností investuje enormné množstvo času do optimalizácie kampaní pomocou komplexných pravidiel. Často to do istej miery funguje veľmi dobre, ale v určitom okamihu už nie je možné dosiahnuť pridanú hodnotu pomocou jednoduchých pravidiel. Umelá inteligencia pomáha cielene využívať marketingový rozpočet prostredníctvom inteligentnej analýzy dát a tým zvyšovať efektívnosť.

V marketingu možno umelú inteligenciu použiť v nasledujúcich prípadoch použitia:

- *Aká je pravdepodobnosť, že zákazník uskutoční nákup v konkrétnej skupine produktov v nasledujúcom mesiaci?*
- *Ktorý reklamný materiál je pre zákazníka ten pravý?*
- *Kedy musím zákazníka osloviť, aby zapadol do jeho nákupného cyklu?*
- *Do akého produktu alebo zmluvy môžem zapojiť zákazníka?*
- *Ktorému zákazníkovi musím dať zľavu na nákup?*

Na tieto otázky (a mnoho ďalších) možno odpovedať pomocou pomerne jednoduchých prístupov umelej inteligencie.

Personalizácia v marketingu

Personalizácia v elektronickom obchode je známy prípad použitia umelej inteligencie. Trend osobného prístupu zákazníkov so správnou ponukou bude pokračovať aj v roku 2021 a bude slúžiť ako rastový faktor pre spoločnosti.

Výhody personalizácie sú zrejmé a dajú sa ľahko merať pomocou jednoduchých testov:

- Silnejšia lojalita zákazníkov
- Viac „Cross – Sellingu“ (krížového predaja)
- Zvýšenie obratu typu „Long-tail“*
- Zvýšenie aktivity zákazníkov

Implementácia je často o niečo zložitejšia, pretože procesy musia byť vysoko automatizované.

Spoločnosti ako Netflix, Spotify, Amazon a Facebook patria medzi absolútnych lídrov v oblasti personalizácie.

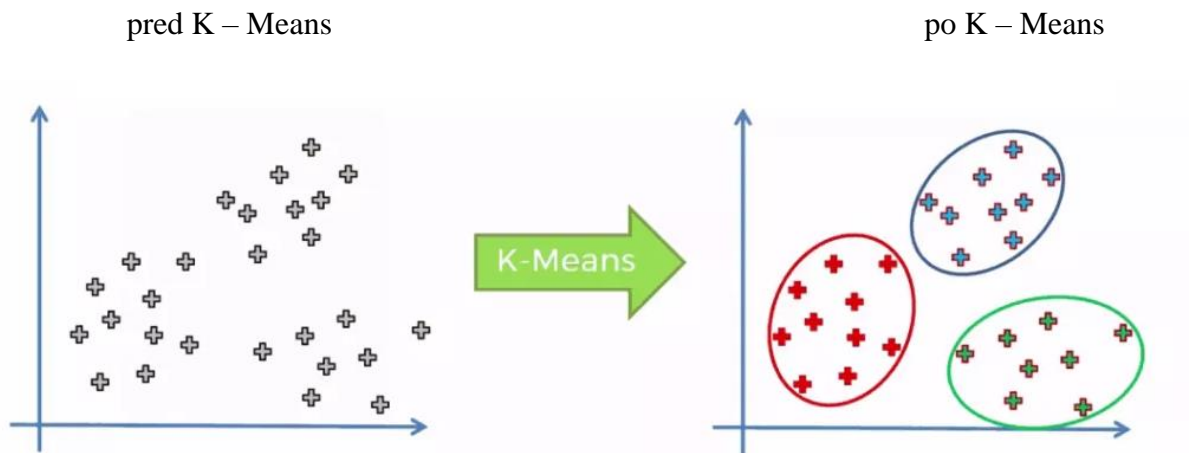
Segmentácia zákazníkov pre marketingové cieľové skupiny

Segmentácie zákazníkov prostredníctvom klastrových algoritmov sú vynikajúcimi príkladmi aplikácie umelej inteligencie v marketingu.

Klastrová metóda je metóda strojového učenia bez dozoru; netrénuje sa na základe cieľovej premennej, ale vytvára nezávislé skupiny a tým rozdeľuje súbor dát.

Klastrová metóda rozdeľuje zákaznícku základňu na určitý počet čo najhomogénnejších podskupín na základe rôznych (behaviorálnych) premenných. Tieto podskupiny sa dajú od seba odlíšiť charakteristickými vzormi. Napríklad zákaznícku základňu možno rozdeliť do 10 - 20 ľahko vysvetliteľných skupín.

Obrázok č.2: K-Means segmentácia zákazníkov v marketingu



Zdroj: Photo by Google Images

Presne definované zákaznícke segmenty poskytujú marketingu hlboký prehľad o vlastnostiach a vzorcoch správania sa cieľových skupín, takže ich možno dobre využiť na optimalizáciu kampaní.

Analýza sentimentu

Analýza sentimentu je hodnotenie neštruktúrovaných údajov, ako sú text, obrázky alebo zvuk. V marketingu sa analýza sentimentu (alebo dolovanie textu) často používa na analýzu komentárov, príspevkov, e-mailov a recenzií z internetu.

V marketingu je analýza sentimentu známa aj ako náladová analýza. Často sa vyskytujúce problémy jednotlivých produktov tak možno rýchlejšie identifikovať alebo rýchlejšie vybaviť reklamácie zákazníkov v prevádzke.

Základom tejto umelej inteligencie je porozumenie prirodzenému jazyku (anglicky: Natural Language Processing). Tu je AI trébovaná na porozumenie a interpretáciu jazyka. Interpretujú sa nielen jednotlivé slová, ale aj kontextové komponenty celého textu.

Optimalizácia vrátených zásielok pomocou umelej inteligencie

Ďalším prípadom použitia umelej inteligencie je optimalizácia vrátených zásielok. Vrátené zásielky predstavujú veľký problém, najmä v maloobchode. Miera vrátených zásielok je často nad 30-40%, čo samozrejme spôsobuje vysoké náklady. Umelá inteligencia pomáha znižovať objem vrátených zásielok prostredníctvom strojového učenia.

Pomocou strojového učenia dostane zákazník presné odporúčania týkajúce sa vhodných veľkostí, preferovaných farieb, štýlov a strihov. Týmto spôsobom sa v procese predaja uskutočňujú intervencie s cieľom znížiť mieru návratnosti. Takýto prístup môže poskytnúť zákazníkovi príslušné odporúčania. Okrem výrazného zníženia návratnosti to má pozitívny vplyv aj na zážitok z nakupovania.

2. Cieľ práce

V dnešnej digitálnej dobe nás realita všedných dní neustále presviedča o dôležitosti (ba až nevyhnutnosti) a význame digitálnych technológií. Pojem „big data“ čiže veľké dáta je nielen výzvou na zber a získanie čo najväčšieho objemu údajov o zákazníkoch a ich nákupnom správaní, ale hlavne veľkou príležitosťou na ich správne spracovanie, vyhodnotenie, predikciu a implementáciu, a to nielen v marketingu.

Hlavným cieľom diplomovej práce je objasniť problematiku, fungovanie a využitie prediktívnych marketingových analýz prostredníctvom nástrojov umelej inteligencie v marketingu. Tento cieľ z praktického hľadiska analyzujeme na modely predvídavého doručenia, patente spoločnosti Amazon. Spoločnosť Amazon je svetovým lídrom v elektronickom obchode a aj autorom viacerých úspešných patentov a inovácií v internetovom obchode. Diplomová práca pozostáva z teoretickej a praktickej časti.

Teoretická časť:

- Objasnenie pojmu “big data” a potreba analýz v marketingu
- Charakteristika súčasných marketingových analytických aplikácií
- Predstavenie nových trendov dátovej analýzy prostredníctvom nástrojov umelej inteligencie
- Definícia umelých neurónových sietí a hlbokého učenia ako kľúčových atribútov umelej inteligencie

Praktická časť:

- Predstavenie spoločnosti Amazon
- Výročná správa
- Opis modelu predvídavého doručenia
- SWOT analýza predvídavého doručenia
- Prieskum verejnej mienky formou dotazníka a výsledky výskumu
- Návrh doporučení pre model predvídavého doručenia

3. Metodika práce a metody skúmania

Pri písaní diplomovej práce, ktorej hlavným cieľom bolo objasniť podstatu a fungovanie prediktívnych marketingových analýz prostredníctvom nástrojov umelej inteligencie sme použili viacero metód zberu údajov, ktorými sme získali potrebné informácie.

Prečítali, analyzovali a spracovali sme domáce i zahraničné odborné knihy a publikácie, vrátane mnohých odborných článkov a blogov na internete s problematikou umelej inteligencie, marketingových analýz, predikcií a veľkých dát.

Teoretická časť začína opisom súčasného stavu marketingu v podmienkach neustále sa vylepšujúcich digitálnych technológií a exponenciálneho rastu užívateľov nakupujúcich v online priestore. Sú predstavené nové trendy spracovania a analýzy dát, rozdelené do jednotlivých kategórií podľa spôsobu použitia, vrátane charakteristiky konkrétnych programov. Nasleduje definícia umelej neurónovej siete a hlbokého učenia, ktoré sú základom fungovania umelej inteligencie.

Posledná časť teoretickej sekcie je venovaná predikcii, objasnenie pojmu a jeho významu v marketingu.

Praktická časť opisuje model predvídateľného doručenia, čo je koncept založený na maximálnom využití prediktívnych marketingových analýz prostredníctvom nástrojov umelej inteligencie. Pri spracovaní profilu spoločnosti Amazon a modelu predvídateľného doručenia boli využité materiály dostupné na internete, vrátane detailov patentu.

Následne sme prostredníctvom SWOT analýzy identifikovali silné a slabé stránky skúmaného modelu od Amazonu. Kľúčové faktory zo SWOT analýzy boli použité ako argumenty a východiskové body pri hodnotení dotazníka.

Prieskum verejnej mienky bol zameraný na zistenie postojov potenciálnych zákazníkov k zavedeniu modelu predvídateľného doručenia do praxe. Zisťovali sme aj vplyv zliav ako motivačného faktora na nákupné rozhodovanie, ako aj mieru vplyvu cielených aktivít na webe Amazon s ohľadom na fakt, že všetky aktivity respondenta na webe môžu byť využité na novú zásielku obsahujúcu tovary ako výsledok prediktívnej analýzy. Respondenti reagovali na 12 otázok, výsledky prieskumu, odporúčania a návrhy riešení sú sumarizované v kapitole „Zhrnutie“.

4. Výsledky práce

Veľké dáta predstavujú veľké množstvo údajov v štruktúrovanej a neštruktúrovanej podobe, ktoré firmy zhromažďujú každý deň. Viac ako ich objem je dôležité, čo sa s týmito údajmi firma rozhodne urobiť. Dnešná prediktívna analýza je rozšírená o technológie umelej inteligencie, ako sú strojové učenie, hlboké učenie a neurónové siete. Tieto rozšírené analytické nástroje môžu rýchlo analyzovať veľké objemy dát, odhaliť statky, ktoré by ľuďom mohli chýbať, a vylepšiť a spresniť predpovedanie pravdepodobnosti budúcich udalostí. Automatizujú tiež komplikované kroky v procese prediktívnej analýzy, napríklad vytváranie a testovanie prediktívnych modelov.

Prediktívna analýza je odvetvie pokročilej analýzy, ktoré predpovedá budúce udalosti, správanie a výsledky. Využíva štatistické techniky - vrátane algoritmov strojového učenia a sofistikovaného prediktívneho modelovania - na analýzu súčasných a historických údajov a na hodnotenie pravdepodobnosti, že sa niečo stane, aj keď to nie je v podnikovom perimetri. Organizácie všetkých veľkostí používajú nástroje prediktívnej analýzy na podporu základných obchodných funkcií, ako je marketing, obchodovanie, predaj a riadenie rizík. Jednou z firiem, ktorá bola vždy na čele inovatívnych spôsobov interakcie online maloobchodu so zákazníkmi je spoločnosť Amazon.

4.1. Profil spoločnosti Amazon

Amazon.com, Inc. je americká nadnárodná technologická spoločnosť so sídlom v Seattli vo Washingtone, ktorá sa zameriava na elektronický obchod, cloud computing, digitálne vysielanie a umelú inteligenciu. Je to jedna z „big five“ spoločností v americkom priemysle informačných technológií spolu s Google, Apple, Microsoft a Facebook. Je to **najväčšie online trhovisko na svete**.

Jeff Bezos založil spoločnosť Amazon zo svojej garáže v Bellevue vo Washingtone 5. júla 1994. Začínala ako online trh s knihami, ale rozšírila sa o predaj elektroniky, softvéru, videohier, odevov, nábytku, potravín, hračiek a šperkov.

Tabuľka č.1 Dlhodobý rast čistého predaja a čistého príjmu Amazonu od roku 1997 do roku 2020



Zdroj: Amazon.com

4.1.1. Finančné výsledky Amazon.com

Finančné výsledky Amazon.com, Inc. (NASDAQ: AMZN) za prvý štvrtrok, ktorý sa skončil 31. marca 2021 sú nasledovné:

- ❖ Prevádzkový peňažný tok sa za posledných dvanásť mesiacov zvýšil o 69% na 67,2 miliardy dolárov, v porovnaní s 39,7 miliardami za posledných dvanásť mesiacov končiacich sa 31. marca 2020.
- ❖ Voľný peňažný tok sa zvýšil na 26,4 miliárd dolárov za posledných dvanásť mesiacov v porovnaní s 24,3 miliardami dolárov za posledných dvanásť mesiacov končiacich 31. marca 2020.
- ❖ Voľný peňažný tok znížený o splátky istiny finančného lízingu a finančných záväzkov sa zvýšil na 14,9 miliárd dolárov za posledných dvanásť mesiacov, v

porovnaní so 14,3 miliardami za posledných dvanásť mesiacov končiacich sa 31. marca 2020.

- ❖ Voľný peňažný tok mínus finančný leasing na vybavenie a splátky istiny všetkých ostatných finančných lízingov a finančných záväzkov sa zvýšili na 16,8 miliárd dolárov za posledných dvanásť mesiacov v porovnaní s 11,7 miliardami dolárov za posledných dvanásť mesiacov končiacich 31. marca 2020.
- ❖ Kmeňové akcie v obehú plus akcie, ktoré sú podkladom pre ocenenie akcií, dosiahli k 31. marcu 2021 spolu 519 miliónov, v porovnaní s 513 miliónmi pred rokom.
- ❖ Čisté tržby sa v prvom štvrtroku zvýšili o 44% na 108,5 miliárd dolárov, v porovnaní so 75,5 miliardami dolárov v prvom štvrtroku 2020. Okrem priaznivého vplyvu 2,1 miliárd dolárov z medziročných zmien devízových kurzov počas celého štvrtroka sa čistý predaj zvýšil o 41% v porovnaní s prvým štvrtrokom 2020.
- ❖ Prevádzkový príjem sa v prvom štvrtroku zvýšil na 8,9 miliárd dolárov v porovnaní s prevádzkovým príjmom 4,0 miliárd dolárov v prvom štvrtroku 2020.
- ❖ Čistý príjem sa v prvom štvrtroku zvýšil na 8,1 miliárd dolárov, alebo 15,79 dolárov na zriadenú akciu, v porovnaní s čistým príjmom 2,5 miliardy dolárov alebo 5,01 dolárov na zriadenú akciu v prvom štvrtroku 2020.

Ciele pre druhý štvrtrok 2021

- Očakáva sa, že čisté tržby budú medzi 110,0 miliardami a 116,0 miliardami dolárov, alebo budú rásť medzi 24% a 30% v porovnaní s druhým štvrtrokom 2020. Tento cieľ predpokladá priaznivý vplyv výmenných kurzov na približne 200 základných bodov.
- Očakáva sa, že prevádzkový príjem sa bude pohybovať medzi 4,5 až 8,0 miliardami dolárov, v porovnaní s 5,8 miliardami dolárov v druhom štvrtroku 2020. Tento cieľ predpokladá náklady vo výške približne 1,5 miliardy dolárov spojené s COVID-19.

- Toto usmernenie okrem iného predpokladá, že sa neuzatvárajú žiadne ďalšie obchodné akvizície, investície, reštrukturalizácie alebo právne vyrovnania.

4.1.2. Amazon ako zamestnávateľ

Spoločnosť Amazon patrí medzi najväčších zamestnávateľov sveta. Prácu v Amazon našlo už viac ako 1 milión zamestnancov po celom svete. V bratislavskej pobočke naštartovalo svoju kariéru v Amazon 850 ľudí a viac ako tisíc zamestnancov v logistickom centre pri Sereďi, ktoré je zamerané na vybavenie nedoručených alebo vrátených zásielok v rámci Európy. Ponuka práce Amazon je stále aktuálna a do logistického centra prijímajú nových zamestnancov bez obmedzenia. Amazon voľné pracovné miesta ponúka v stabilnej spoločnosti s atraktívnym balíčkom finančných a nefinančných benefitov, kam patrí ročný bonus, doplnkový systém zdravotnej starostlivosti, životné poistenie, plán dôchodkového sporenia, cenovo zvýhodnené stravovanie a ďalšie atraktívne benefity.

Tabuľka č.2 Dlhodobý rast počtu zamestnancov Amazonu od roku 2007 do roku 2020



4.2. Model predvídavého doručenia

Existuje veľké množstvo údajov, ktoré zdieľame s online maloobchodníkmi vedome alebo nevedome. Zakaždým, keď klikneme na produkt ponúkaný online, v databáze organizácie sa uloží doba zobrazenia produktu, čas strávený na webe, predchádzajúce aktivity na webe, obsah nákupného košíka, údaje v zozname želaní atď. Okrem toho organizácie využívajú informácie z reálneho sveta získané z dotazov zákazníkov a odpovedí na marketingové úsilie. Tieto údaje sú spracovávané algoritmom umožňujúcim špekulatívne doručenie výrobkov. Maloobchodníci predpokladajú, kedy si môže zákazník produkt objednať a odoslať ho do blízkych prepravných uzlov pred zadaním objednávky. To nakoniec vedie k veľmi vysokej rýchlosti dodávky zabezpečením expedície produktu ihneď po objednaní.

24. decembra 2013 bol spoločnosti Amazon udelený americký patent „Method and System for Anticipatory Package Shipping“. Patent popisuje spôsoby prepravy komodít na základe vypočítanej pravdepodobnosti (potenciálnych) zákazníkov, ktorí si objednávajú tovar z Amazonu: pri predbežnej preprave sa balíčky odosielajú „v očakávaní zákazníka, ktorý si objedná položky v tomto balíku, ale skôr, ako k takejto objednávke skutočne dôjde“. Predikcia (potenciálneho) nákupu sa tak počíta na základe predchádzajúcich vzorcov v sledovaných interakciách zákazníkov s platformou elektronického obchodu vrátane nákupov a miery kliknutí. Výsledkom je, že patent naznačuje, že proces prepravy balíka už nebude iniciovaný zákazníkom stlačením tlačidla kúpiť, ale algoritmom, ktorý predpovedá budúce požiadavky zákazníkov v rôznych regiónoch. Vďaka tomuto využitiu prediktívnych analýz na prepravu tovaru sa môže doba dodania ešte znížiť, čo poskytuje dôležitú konkurenčnú výhodu. Predvídavá preprava sleduje ideály zamerania na zákazníka, neustálej optimalizácie, kultúry inovácií a podnikovej agility.

Ústrednou súčasťou tohto obchodného modelu je odporúčací systém spoločnosti Amazon. Odporúčania vychádzajú z údajov o zákazníkoch, nie je založená iba na nákupoch, ale aj na histórii prehliadania, vzoroch hodnotení používateľov a mnohých ďalších faktoroch. Odporúčania sa umiestňujú na platformu elektronického obchodu a vychádzajú presne z týchto parametrov. Pre svoj odporúčací systém Amazon využíva metódu, ktorá umožňuje identifikáciu nielen osobnej histórie nákupu, ale aj personalizáciu na základe identifikácie

skupinového správania. Ak prechádzame určitú položku, odporúčanie je založené na histórii prehliadania iných „jednotlivcov“: používatelia, ktorí si prezreli túto položku, si tiež prezreli túto položku. To však ovplyvňuje prepojenie aktívnych osôb na konkrétnom trhu. Systém odporúčaní sa stáva výpočtovým režimom organizácie trhu, ktorý zahŕňa určitých účastníkov trhu a iných predvolene vylučuje. Tento segmentačný mechanizmus je samozrejme možné prekonať individuálnym vyhľadávaním, interakcie sú však stále výrazne štruktúrované.

Okrem informačného systému má rozhodujúcu úlohu aj logistika. Zatiaľ čo logistika bola vždy zameraná do predpovedania trhov a dopytu do istej miery, predvídave doručenie funguje na inej úrovni. Predikcia sa nezameriava na dopyt celého regiónu po určitom type produktu - agregácia je omnoho viac zmenšená. Predikcie sú predmetom jedinečných nákupov produktov, ktorých výsledkom sú balíčky iba niektorých položiek, ktoré sa majú distribuovať v rámci logistickej infraštruktúry Amazonu. Namiesto prepravy väčšieho množstva tovaru, aby sa uspokojil očakávaný dopyt, sa vytvárajú jedinečné spojenia medzi prepravou a (pravdepodobným) nákupom a zabezpečujú sa pomocou technologického pokroku, čo si vyžaduje integráciu rôznych distribučných stratégií, ktoré ukazujú väčšiu flexibilitu. Predikcia sa spolieha na celkový mediálny odkaz na digitálnej báze, ktorý umožňuje spojenie každého a všetkého so všetkým a so všetkými ostatnými.

Kombinácia logistických médií s digitálnymi trhmi vytvára ešte silnejšie trhy, vďaka čomu sú predpovede presnejšie bez zmeny modelu, ktorý stojí za metódou predvídaveho doručenia. **Dopyt sa nepredpovedá, ale sa vyrába.**

4.2.1. Úloha veľkých dát

Veľkými dátami sa rozumie prax zhromažďovania informácií v digitálnej forme z mnohých zdrojov a analytická analýza na identifikáciu trendov, vzorov a súvisiacich inteligencií. Analýza vykonaná na základe údajov môže poukazovať na scenáre, ktoré sa stali, ale nebolo ľahké ich vnímať, alebo môže pomôcť pri predpovedaní toho, čo sa stane v budúcnosti. Dôležitosť veľkých dát v predvídavom doručení je spôsobená obrovským objemom informácií, ktoré sa majú analyzovať. Patria sem údaje v doméne dodávateľského reťazca, ako sú údaje o mieste predaja, čítačky RFI, snímače čiarových kódov, zariadenia GPS na

vozidlách a mobilných zariadeniach a údaje v reálnom čase zo softvérových systémov používaných na správu prepravy a skladovania.

4.2.2. Pridaná hodnota a vplyv na dodávateľský reťazec

Zdieľaním a integráciou údajov o správaní sa zákazníkov z tradičných a nových zdrojov údajov do najmodernejších analýz založených na veľkých dátach sa dá dosiahnuť obrovský dopad v dodávateľskom reťazci. Môže to mať formu zvýšenej efektívnosti nákladnej dopravy, zvýšenej kapacity a využitia zdrojov, harmonogramov synchronizovanej dopravy podporujúcich synchronodálne alebo iné inteligentné logistické siete a zníženého rizika narušenia dodávateľského reťazca.

Algoritmus predvídateľného doručenia môže hrať dôležitú úlohu pri predpovedaní objemov a optimalizácii využitia kapacity. Veľký objem predpovedí založený na dátach a techniky využitia kapacity zlepšia presnosť predpovedí očakávaných objednávok a požiadaviek na prepravu v sieti koreláciou údajov z rôznych zdrojov a s rôznymi stupňami ochrany súkromí

Ďalším prírastkom hodnoty v dodávateľskom reťazci je prediktívne riadenie rizík v dodávateľskom reťazci, ktoré obsahuje techniky využívajúce algoritmy veľkých dát na simuláciu rôznych možných scenárov dodávateľského reťazca s ohľadom na potenciálne riziká. Poskytovatelia služieb tak budú mať možnosť zvoliť si najvhodnejší scenár podľa trhových faktorov, aby sa zabránilo prerušeniu výroby a výrobkov.

Účinok novej technológie však nie je bez chýb. Akokoľvek je softvér sofistikovaný, neexistuje spôsob, ako spoznať nevyslovené nákupné dôvody zákazníka a presne predpovedať jeho správanie. Spoločnosť Amazon bude musieť preventívne posielat' svoje produkty špekulatívne zaujatým kupujúcim na základe výskumu vzorcov prehliadania a nákupu v minulosti. Mnohé z týchto vzorov však nebudú skutočným odrazom osobných záujmov kupujúceho a na základe nesprávnej analýzy budú mať za následok výdavky na dopravu.

4.2.3. Vplyv na konečného zákazníka

Najväčšou výhodou pre zákazníka, ako je zrejmé z vyššie uvedeného, je to, že vyrieši hlavnú kritiku, ktorej čelí online maloobchodný predajca vo vzťahu k tradičným maloobchodným predajcom v kamenných prevádzkach- niekoľkodňové alebo týždenné oneskorenie v dodávaní produktov do rúk zákazníka. Zároveň tento model boduje v troch primárnych elementoch spotrebiteľskej psychológie - potešenie, zľavy a ponuky - na ktoré sa Amazon zameriava. Predvídave doručenie zvyšuje potešenie zákazníka a zvyšuje jeho spokojnosť super-rýchlou dodávkou. Pomáha tiež pri budovaní reputácie Amazonu v oblasti obchodov a zliav prenosom úspory logistických nákladov na zákazníkov.

Aj keď ide o revolúciu v spôsobe interakcie maloobchodného predaja online so zákazníkmi, zákazníci môžu byť znepokojení otázkami ochrany súkromia. Zákazníci nemusia reagovať pozitívne na ukladanie a použitie svojich online aktivít na komerčné účely. V dekáde, kedy je súkromie v digitálnom priestore páľčivou otázkou, bude mať komerčné sledovanie digitálnej stopy večný vplyv na imidž spoločnosti.

4.3. SWOT analýza modelu predvídave doručenie

SWOT analýza nám pomôže posúdiť predpoklady podniku uskutočniť implementáciu stratégie predvídaveho doručenia na trhu. SWOT analýza využíva výsledky predchádzajúcich analýz tým, že identifikuje hlavné silné a slabé stránky podniku a porovnáva ich s hlavnými príležitosťami a rizikami, ktoré skrýva externé prostredie³.

4.3.1. Silné stránky

Nižšie náklady

Predpovedaním toku balíkov až do miesta dodania sa náklady na skladovanie zásob výrazne znižujú, keďže náklady na zásoby môžu predstavovať až 45% - 80% obchodných nákladov. Riešením nákladov na zásoby by teda viedlo k nižším nákladom, a preto by sa mohli

³ Dagmar Lesáková a kolektív, (2014). *Strategický marketing*. ISBN: 9799089710072. Str.41

spotrebiteľom ponúkať nižšie ceny. To následne povedie k zvýšeniu výnosov a vyššej produktivite.

Rýchlejšie dodanie

Celkovým cieľom je rýchlejšie získať objednávky k zákazníkom. V mnohých prípadoch to môže predpokladaný model prepravy umožniť. Úradníci spoločnosti Amazon veria, že počet dodávok v rovnaký deň aj nasledujúci deň sa exponenciálne zvýši.

Vernosť zákazníkov

Predbežná doručenie by mohla niektorým zákazníkom poskytnúť zľavy - alebo dokonca priamo dary - na výrobky, ktoré zákazníci dostali, ale nechcú. Maloobchodník by mohol pomocou svojich údajov o cenovej citlivosti domácností a ponuke a dopyte rozhodnúť, ktoré produkty a ktoré domácnosti sú oprávnené na takéto obchody.

Rastúci záujem o používanie veľkých dát

Organizácie začínajú začleňovať Big Data do svojich procesov a využívať výhody. Autori správy „Big data, analytics and the way from insights to value“ zistili, že použitie Big Data a ich analytík by spôsobilo, že podnik bude mať dvakrát vyššiu pravdepodobnosť, že bude na svojom trhu najvýkonnejším.

Zhromažďuje sa a uvoľňuje sa veľké množstvo údajov

Ďalšou silnou stránkou spoločnosti Big Data je množstvo údajov o spätnej väzbe od zákazníkov, ktoré sú dostupné prostredníctvom sietí sociálnych médií, ako sú Facebook a Twitter. Lepšie zameraný marketing v oblasti sociálneho vplyvu bol na požiadanie na vrchole zoznamu aké výhody by priniesla implementácia akejkoľvek analýzy veľkých dát. Tento dopyt po analýze veľkých dát bude ešte väčší, keď sa v budúcnosti k sietiam sociálnych médií pripojí čoraz viac ľudí.

Ďalší predaj

Amazon je presvedčený, že aj keď nie je v poriadku s dodávkou, mohol by zúročiť ďalší predaj. Spoločnosť je presvedčená, že zdravé percento zákazníkov by si položku jednoducho nechalo a zaplatilo za ňu.

Optimalizácia zásob

Sklady sa môžu vyhnúť vyčerpaniu zásob alebo nadmernému skladovaniu zásob optimalizáciou zásob na základe predpokladaného budúceho dopytu po určitých produktoch. Prediktívna analýza tiež ponúka informácie o spotrebiteľských nákupných vzorcoch, čo pomáha skladom udržiavať presnejšie úrovne zásob a robiť inteligentnejšie rozhodnutia v oblasti riadenia zásob.

Predikcia dopytu

Dopyt ovplyvňuje niekoľko faktorov a táto zložitosť sťažuje presnú predpoveď. Vďaka prediktívnej analýze však kombinácia historických údajov a informácií o trhu dokáže vygenerovať veľmi presnú predpoveď dopytu, ktorá umožňuje vyváženie aktív v akejkoľvek logistickej sieti pri minimálnych nákladoch.

Riadenie zásob

Manažéri dodávateľského reťazca pomocou prediktívnej analýzy môžu určiť optimálnu úroveň zásob na uspokojenie dopytu pri znížených nákladoch pre každé miesto. To umožňuje znížiť úroveň bezpečných zásob aj zásob. Ak má spoločnosť viac distribučných centier, táto schopnosť sa stáva veľmi užitočnou, pretože pomáha manažérom dodávateľského reťazca vedieť, kde by sa mali skladovať zásoby (centrálne alebo regionálne).

4.3.2. Slabé stránky

Nedostatok vedomostí a porozumenia

Ako sa analýza veľkých dát stáva populárnejšou a štandardnejšou súčasťou modernej podnikových procesov, bude potrebné ďalšie školenie a prenos znalostí s cieľom analyzovať údaje, ktoré zhromažďujú, a získať tak lepší prehľad o tom, čo ich zákazníci chcú a potrebujú.

Neúplnosť

Presnosť prediktívnych analytických modelov je obmedzená úplnosťou a presnosťou použitých údajov. Ak sú zadané údaje nepresné, ovplyvní to výstup a bude to nespoľahlivé. Nedostatky v údajoch môžu viesť k nedostatkom v modeli.

Dátová krátkozrakosť

Profily zákazníkov sa navrhujú podľa pokynov založených na očakávaniach ľudí, ale obmedzenia rozsahu rôznych demografických premenných môžu viesť k tomu, že zákazníci budú klasifikovaní príliš obmedzenými spôsobmi.

Zúženie

Spoliehanie sa na prediktívne analytické modely, ktoré majú viesť obchodné procesy k ovplyvňovaniu správania zákazníkov, môže vytvárať umelé hranice, ktoré zužujú rozsah očakávaného správania zákazníka.

Nepresné objednávky

Čo sa stane v prípade, ak zákazník produkt neprivíta? Môžu existovať určité prípady, kedy by predvídanie zlyhalo.

Vysoká miera vrátenia tovarov

Odvetvie elektronického obchodu trpí vysokou mierou návratnosti. Okrem toho existuje možnosť, že pri predpokladanom odoslaní môže algoritmus veľkých dát zlyhať, čo povedie k nákladným návratom.

Nepredvídané udalosti

Prediktívne analýzy môžu naraziť na vážne problémy s akoukoľvek nepredvídanou udalosťou. Môže to byť napríklad politický prevrat, prírodná katastrofa, krach burzy alebo niečo, čo môže mať zásadne nepriaznivý vplyv na predpoveď. Neexistuje však spôsob, ako takéto udalosti predvídať.

Absencia etického kódexu

Etický kódex je súbor všeobecne uznávaných a všeobecne uplatňovaných morálnych noriem, ideálov a princípov spoločnosti, pre ktorú je určený, ktoré idú nad rámec legislatívne upravených zákonov. Pre predvídajúce doručenie etického kódexu k dispozícii nie je.

4.3.3. Príležitosti

Rastúci trh

Jednou z najväčších príležitostí pre odvetvie online nakupovania je rastúci trh. Aj keď väčšina spotrebiteľov v rozvinutých krajinách už elektronické zariadenia má, v rozvojových krajinách je veľa spotrebiteľov, ktorí tak neurobia - a v dôsledku toho nekúpia tovar online. Keďže ceny elektroniky naďalej klesajú, je pravdepodobné, že zaznamenáme zvýšenie počtu potenciálnych internetových nakupujúcich. To následne povedie k väčšiemu objemu predaja.

Influenceri

Existuje niekoľko používateľov internetu, ktorí využívajú svoje veľké sociálne aktivity na propagáciu rôznych tovarov a služieb. Títo ľudia, známi ako influenceri, predstavujú skvelú marketingovú príležitosť pre podporu konceptu predvídateľného doručenia.

Automatizácia musí byť viackanálová

Okamžitou výzvou pre vývojárov automatizácie analýzy je vytvorenie riešenia, ktoré sa posúva ďalej ako do bodu a do viackanálového prostredia.

Odvrátenie paralýzy analýzou

Automatizácia vytvára kultúru založenú na dátach, pretože umožňuje rýchlejšie vykazovanie, analýzu a optimalizáciu existujúcich kanálov na základe známeho. Toto použitie údajov ako príkladu pohodlia však môže inovatívne organizácie pomaly udusiť. Spoločnosti majú veľa ľudí analyzujúcich správy, ktorí sa snažia identifikovať medzery a príležitosti v taktickom výkone, aby mohli vykonať predvídateľné úpravy. Výsledkom je, že spoločnosti najímajú veľa ľudí, ktorí sa radi snažia myslieť ako počítač. Ak by sa všetky tieto procesy dali automatizovať, cieľom by malo byť nábore rôznych typov mysliteľov,

4.3.4. Hrozby

Falošní spotrebitelia

Ďalšou slabou stránkou by mohlo byť, keď sa spotrebiteľ zámerne správa ako príjemca pozornosti.

Monopolizácia

Pretože obchody eCommerce sú schopné uspokojiť celé krajiny alebo dokonca celý svet, ponecháva veľký potenciál pre vznik monopolov. Asi najlepším príkladom je to, ako Amazon ovplyvnil kníhkupectvá. V minulosti obsluhovali danú oblasť rôzne miestne kníhkupectvá (vrátane obchodov s matkou a popom, menších reťazcov a väčších reťazcov). S príchodom alternatív elektronického obchodu, ako je Amazon, tieto obchody vymierajú a Amazon sa stáva jednotným kontaktným miestom pre knihy. Tento trend sa môže rozšíriť na ďalšie trhy a môže si v určitom okamihu vyžadovať vládnu reguláciu.

Nebezpečenstvo strojovej inovácie

Aj keď marketingovým pracovníkom môže hroziť, že zabudnú na hodnotu svojich ľudských zdrojov v prospech rýchlosti a efektívnosti automatizácie, existuje tiež riziko spoliehať sa 100% na dátové výstupy, aby informovali o ďalšom smerovaní. Prílišné spoliehanie sa na údaje, ktoré majú podložiť rozhodovanie, brzdí inovácie.

Obavy o súkromie

Pretože sa zhromažďuje čoraz viac údajov, existuje riziko, že niektoré z týchto údajov budú použité nevhodne a zvyšuje sa znepokojenie nad online nakupovaním z dôvodu krádeže identity a hackerstva, ktoré nechávajú údaje spotrebiteľov odhalené. Preto musí spoločnosť Amazon rýchlo postupovať, aby odbúrala obavy spotrebiteľov týkajúce sa jej stránky, a zabezpečiť, aby bolo zaručené súkromie a bezpečnosť online.

Neštruktúrované dáta

V minulosti boli databázy štruktúrované spolu s príslušnými modelmi a softvérom vytvoreným na efektívnu analýzu týchto údajov. Vďaka obmedzenému množstvu zhromaždených a uložených údajov bolo možné súbory údajov spravovať a udržiavať v organizácii. Väčšina, ak nie všetky, množiny údajov používaných v analýze veľkých dát sú však mimoriadne neštruktúrované. Mať neštruktúrované údaje znamená, že je potrebné

vynaložiť prostriedky na čistenie a „vyčistenie“ údajov pred dokončením akéhokoľvek spracovania.

Strašidelnosť

Automatizované systémy sú už dlho schopné jednoduchého sledovania reklám, pri ktorých weby vypúšťajú súbory cookie, ktoré poskytujú informácie, ku ktorým majú prístup partneri v rámci reklamnej siete. Systémy sú čoraz viac schopné skenovať akcie zákazníkov v hierarchickom sémantickom kontexte a poskytovať tak viac informácií o záujmoch zákazníkov. Hľadané výrazy osoby spojené s návštevou stránky produktu môžu poskytnúť dostatok informácií na vyvodenie záveru o tom, čo zákazník skutočne hľadá. Keď sa však tieto kúsky informácií používajú na prezentáciu reklám a umiestňovanie produktov, zákazníci sú znervóznení automatizovanými systémami, ktoré sa snažia predvídať ich zámer a ovplyvniť ich aktivity.

Obavy zamestnancov

Niektorí zamestnanci sa môžu obávať alebo mať strach z prechodu od tradičných metód analýzy údajov. Preto je dôležité, aby organizácie definovali a uvádzali, ako prediktívna analytika zjednoduší úlohy organizácie a jednotlivcov.

Dotieravý a/alebo urážlivý dojem

Aj keď sa určitá časť môže rozhodnúť zaplatiť za položku a ponechať si ju, ostatným sa zásielky pravdepodobne budú javiť ako rušivé a/alebo urážlivé. Je možné, že by to mohlo spôsobiť zlú vôľu zákazníkov a odvieť ľudí od nákupu položiek od Amazonu.

Tabuľka č.3 SWOT analýza predvídavého doručenia

	POZITÍVNE	NEGATÍVNE
INTERNÉ	<p>Silné stránky</p> <ul style="list-style-type: none"> - nižšie náklady - rýchlejšie dodanie - vernosť zákazníkov - rastúci záujem o používanie veľkých dát - zhromažďuje sa veľké množstvo údajov - ďalší predaj - Optimalizácia zásob - Predikcia dopytu - riadenie zásob 	<p>Slabé stránky</p> <ul style="list-style-type: none"> - nedostatok vedomostí a porozumenia - neúplnosť - dátová krátkozrakosť - zúženie - nepresné objednávky - vysoká miera vrátenia tovarov - nepredvídané udalosti - absencia etického kódexu
EXTERNÉ	<p>Príležitosti</p> <ul style="list-style-type: none"> - rastúci trh - influenceri - viackanálová automatizácia - odvrátenie paralýzy analýzou 	<p>Hrozby</p> <ul style="list-style-type: none"> - falošní spotrebiteľia - monopolizácia - nebezpečenstvo strojovej inovácie - obavy o súkromie - neštruktúrované dáta - strašidelnosť - obavy zamestnancov - dotieravý a/alebo urážlivý dojem

Zdroj: vlastné

4.4. Prieskum verejnej mienky

Za účelom zistenia verejnej mienky na zavedenie modelu predvídavého doručenia do praxe bol vypracovaný dotazník, ktorý bol rozoslaný v on-line forme z webovej lokality: <https://www.surveio.com/survey/d/R3V3A4E8T5P6IOJ7F>

Cieľom dotazníka bolo zistenie základných postojov k elementárnym prvkom modelu predvídavého doručenia, a to príjem zásielky, vrátenie zásielky, rozhodnutie o nákupe a vernosti k značke. Samotný proces dopytovania respondentov vyvolal mnohé emócie.

Dotazník obsahoval 12 otázok, 3 z nich boli demografické položky. Na výber boli vždy 4 odpovede, a to:


- Áno
- Skôr áno
- Nie
- Skôr nie

Prieskumu sa zúčastnilo 60 respondentov. Jednotlivé otázky sú znázornené vo forme grafov nižšie. Na úvod boli respondenti oboznámení dôležitosťou výskumu a potreby informácií, ako aj garantovaním anonymity:

„Vážená pani, Vážení pán,

dovoľte mi obrátiť sa na Vás s prosbou o vyplnenie tohto dotazníka, ktorý slúži na analýzu postoja verejnosti k zavedeniu do praxe modelu predvídavého doručenia, pri ktorom prostredníctvom prediktívnej analýzy a umelej inteligencie spoločnosť Amazon predpovedá budúci dopyt potenciálnych zákazníkov. Dotazník je anonymný a všetky získané informácie sú dôverné a budú slúžiť len na vedecké účely. Vopred Vám ďakujeme za spoluprácu.“


Graf č. 1: Amazon by Vám chcel poslať tovary, o ktorých predpokladá, že budete mať o ich kúpu záujem. Prevzal/a by ste takúto zásielku?




Prieskumom sme zistili, že 82% respondentov má negatívny postoj k obdržaniu neočakávaných zásielok, ktorým nepredchádzala ich objednávka, z toho 32% respondentov by takúto zásielku určite neprevzalo. Tento negatívny postoj drvivej väčšiny respondentov ovplyvňuje viacero faktorov, medzi tie najvýraznejšie však patria presýtenosť všedných dní komerciou a pocit narušenia súkromia. Občan ako potenciálny zákazník je nepretržite konfrontovaný snahou obchodníkov zaujať ich ponukou a predat' svoje produkty (inzercia, reklama, akcie, benefity), čo v mnohých prípadoch vedie až averzii a nekompromisnému negovaniu nových resp. ďalších pokusov o predaj. K narušeniu pocitu súkromia dochádza hneď z dvoch hľadísk, a to jednak v dôsledku uvedomenia si skutočnosti, že naše aktivity na internete nie sú privátne, práve naopak, sú nepretržite archivované, analyzované a použité pre ďalšie spracovanie bez nášho vedomia; a jednak takýmto spôsobom Amazon vnucuje svoje produkty a tým pôsobí na výber a formu nákupu produktov podľa vlastného uváženia.

Iba 1% respondentov by predvídateľnú zásielku prijalo bez výhrad a 14% respondentov predpokladá skôr kladný postoj a predvídateľnú zásielku od Amazonu by pravdepodobne prevzalo. Taktiež je vysoko pravdepodobné, že odmietanie predvídateľnej zásielky súvisí s faktom, že sa jedná o výrazne narušenie pocitu súkromia jednotlivca pri prezeraní internetu, nakoľko zhmotňuje jeho prehľadávanie, nie objednávku.

Graf č. 2: Je pre Vás prijateľné, balík s tovarmi, ktoré sa rozhodnete si neponechať, zabaliť a odovzdať na pobočke pošty?



Graf č. 3 Je pre Vás prijateľné, aby balík s tovarmi, ktoré sa rozhodnete si neponechať, vyzdvihol u Vás doma kuriér?




Ďalším z možných dôvodov negatívneho postoja k predvídavým, no neočakávaným zásielkám je skutočnosť, že sú spojené aj s dodatočnou manipuláciou. Vychádzajme z predpokladu, že spotrebiteľ zákazku nejakým spôsobom prevzal. Často sú balíky doručené bez osobného kontaktu a adresát, s pocitom zodpovednosti, je tak vystavený následnej manipulácii so zásielkou bez ohľadu nato, či má alebo nemá o ňu záujem. Zároveň aj keby sa adresát rozhodol zásielku prevziať a doručené tovary pozrieť prípadne vyskúšať, je veľmi pravdepodobné, že nebude mať záujem o všetky produkty v balíku. V takom prípade je nutné vynaložiť dodatočné úsilie a tovary zabaliť a vrátiť.


Otázkami č.2 a č.3 sme zisťovali, do akej miery je pre adresáta obťažujúce nechcené tovary zabaliť a odovzdať na pobočke pošty, čo by bolo pre Amazon výhodnejším, lacnejším a teda želaným spôsobom vrátenia tovarov predvídaveho doručenia. Pre 23% respondentov je doručenie predvídavej zásielky na pobočku pošty neprijateľné, ďalších 38% respondentov má negatívny postoj k tomuto spôsobu vrátenia tovarov predvídaveho doručenia. Iba 20% respondentov nemá výhrady odovzdať nechcené tovary na pošte.

Prieskumom tiež zistilo, že pokiaľ by vrátenie tovarov bolo zabezpečené kuriérskou službou a adresátovi by stačilo len tovar zabaliť a pripraviť pre odoslanie, až 85% respondentov by samotný proces vrátenia tovaru nevnímalo ako problém.


Graf č. 4 Ponechal/a by ste si pôvodne odmietnuté tovary, keby boli zvýhodnené dodatočnou zľavou 15%?



Graf č. 5 Ponechal/a by ste si pôvodne odmietnuté tovary, keby boli zvýhodnené dodatočnou zľavou 50%?




Graf č. 6 Ponechal/a by ste si pôvodne odmietnuté tovary, keby Vám ich Amazon ponechal ako darček?




Otázkami č. 4 až č. 6 sme zisťovali vplyv cenových zliav na motiváciu adresáta ponechať si pôvodne odmietnutý tovar. Darovaný tovar by si určite ponechalo 73% respondentov. Nízka zľava vo výške 15% by neovplyvnila 85% respondentov, avšak zľava vo výške 50% by motivovala príjemcu zmeniť svoje rozhodnutie a tovar si predsa ponechať u 50% respondentov.


Graf č. 7 Realizoval/a by ste viac prehliadaní na webe Amazonu s vedomím, že to ovplyvní nasledujúcu zásielku predvídávého doručenia?



Graf č. 8 Realizoval/a by ste viac nákupov na webe Amazonu s vedomím, že to ovplyvní nasledujúcu zásielku predvídavého doručenia?



Graf č.9 Vracal/a by ste menej objednaných tovarov z Amazonu s vedomím, že to ovplyvní nasledujúcu zásielku predvídavého doručenia?



Z výsledkov grafov č. 7 až č. 9 vyplýva, že 75% respondentov by nezmenilo svoje aktivity vo vzťahu k Amazonu s cieľom nejakým spôsobom ovplyvniť budúce predvídajúce zásielky, práve naopak, mnohých by táto skutočnosť motivovala redukovať terajšie aktivity na webe Amazonu, a to bez ohľadu nato, či sa jedná o nákupy, vrátenia tovarov alebo len prehliadanie webu. Iba pre 25% respondentov by bolo predvídajúce doručenie dôvodom pre zvýšenie aktivít a operácií na webe Amazonu, ako aj obmedzenie vrátenia vedome objednaných tovarov.

Demografické položky dotazníka:

Pohlavie	počet respondentov	podiel
Muž	42	70%
Žena	18	30%

Vek	počet respondentov	podiel
31 - 55	53	88.3%
18 - 30	5	8.3%
55 a viac rokov	2	3.3%

Vzdelanie

Vysokoškolské	41	68.3%
Stredoškolské s maturitou	18	30%
Stredoškolské bez maturity s výučným listom	1	1.7%
Základné	0	0%

4.5. Zhrnutie výsledkov práce

Súčasný stav hospodárstva, kde ponuka výrazne prevyšuje dopyt, je spotrebiteľ denne vystavený tlaku obchodníkov a ustrážiť svoj kapitál je častokrát náročné. Nákupom a objednávkam spotrebiteľov spravidla predchádza úvaha, prieskum trhu, hodnotenie alternatív a výber produktu, a teda je tento proces plánovaný a premyslený. Aj keď presnosť výstupov predikcií sa v porovnaní s minulými obdobiami výrazne zvýšila, nie sú zárukou dopytu užívateľa, nakoľko berú do úvahy iba aktivity a operácie, ktoré sú prostredníctvom algoritmov strojového učenia a umelou inteligenciou spracovateľné a je možné ich následne analyzovať. Výsledok predikcie Amazonu neuvažuje viacero dôležitých premenných, ako napríklad nákupy v hotovosti, dary, sociálne zmeny, emócie, pocity a zmeny nálad atď.

Jedným z hlavných dôvodov negatívneho postoja respondentov k modelu predvídávého doručenia je teda skutočnosť, že Amazon takto prekračuje prirodzenú hranicu propagácie tovarov a podsúva ich užívateľovi ako nepriamu formu jeho objednávky, čím ho určitým spôsobom **núti k neplánovaným nákupom podľa očakávaní Amazonu**. V prenesenom význame návšteva webu Amazonu pripomína koridu a užívateľ, ktorý je v pozícii nič netušiaceho býka, neopustí arénu bez toho, aby si niečo nekúpil resp. pre niečo neprejavil záujem. Preto niet divu, že vyše 80% respondentov má negatívny postoj zásielku predvídávého doručenia čo i len prevziať.

Predvídavé doručenie je vnímané aj ako **ekologický problém**, pretože v prípade aplikácie modelu predvídávého doručenia do praxe by došlo k enormnému navýšeniu dopravy, čo by malo negatívny dopad na klímu, ekosystém a celkový imidž krajiny. Zámer Amazonu, nechcené produkty ponechať ako darček zároveň hrubo znehodnocuje tovary a dehonestuje ich výrobu, ktorá v mnohých prípadoch prebieha v katastrofálnych podmienkach vrátane odmeny za prácu.

V dlhodobom časovom horizonte by aktívny model predvídávého doručenia určite výrazne obmedzil nakupovanie v kamenných obchodoch, ktoré je popri rodine, škole a práci jednou z hlavných foriem socializácie jednotlivca v spoločnosti. Spontánne stretnutia známych medzi regálmi, ochutnávky produktov miestnych farmárov v prevádzke maloobchodu, získavanie informácií od odborníkov dôležitých pre výber vhodného produktu, to všetko by padlo za obeť prediktívnym nástrojom Amazon a pre mnohých užívateľov by to bola **strata významného priestoru socializácie**.

Ďalším dôležitým faktorom, ktorý je nevyhnutné v súvislosti s implementáciou predvídateľného doručenia spomenúť, je **konkurencia**. Mohlo by sa zdať, že patentovaním tohto modelu sa Amazon zbavil konkurencie, avšak stačí zanedbateľná modifikácia jedného z mnohých procesov a článkov v distribučnom reťazci a konkurenti budú môcť doručovať predvídateľné zásielky tiež, bez hrozby sankcií za porušenie patentu. Faktom je, že model doručenia tovarov, ktorý vychádza z odhadov budúcich dopytov už dlhodobo funguje v námornej doprave, s cieľom skrátiť príliš dlhotrvajúci proces doručenia tovaru zákazníčkovi. Nasledovať model predvídateľného doručenia si nemôže dovoliť každý e-shop, no giganti online obchodu, ako napríklad Alibaba, majú možnosti, zdroje aj potenciál aktívne konkurovať Amazonu aj pri takejto forme predaja. V súvislosti s konkurenciou sa vynára ďalší problém – predstavme si, že by sa konkurencia, rovnako ako Amazon, rozhodla realizovať predaje nie na základe objednávok užívateľov, ako je tomu dnes, ale na základe jej odhadov. Spustilo by to zásielkovú lavínu a mohla by nastať situácia, že každé ráno budú vítať nič netušiacich občanov nastohované kartóny pred vchodovými dverami. Takáto predstava je katastrofický scenár.

Vnímanie technologického pokroku a umelej inteligencie ako takej je často negatívne, napriek tomu, že mnohé nástroje umelej inteligencie sú súčasťou nášho každodenného života a užívame ich so samozrejmosťou, avšak mnohokrát bez vedomia, že sa jedná o umelú inteligenciu. Jedným z hlavných dôvodov negatívneho postoja k umelej inteligencii je **obava z tzv. Super inteligencie**, kedy sa technológia dostane do bodu, v ktorom sa môže sama učiť, zdokonaľovať a vymýšľať, a namiesto toho, aby sa stala hybnou silou pre zlepšenie ľudstva, stane sa ľudstvo služobníkom technológie. Výpočtové systémy by sa mohli dostať do bodu, kedy predbehnú svojich ľudských tvorcov a ich mozgové kapacity, a spoločnosť nebude schopná prijať ochranné opatrenia, ktoré by zabránili počítačom v dosiahnutí tohto bodu.

4.5.1. Návrhy riešení

Ako možné riešenia úspešnej implementácie predvídateľného doručenia navrhujeme nasledovné alternatívy:

Segmentácia produktov v užívateľskom profile Amazonu, a teda, že užívateľ si sám určí kategórie produktov, ktoré by bol ochotný prijať predvídateľnou zásielkou. Amazon by

napríklad formou nejakého bonusu motivoval užívateľa k vyplneniu dotazníka, kde by bolo zrejmé, ktoré tovary predstavujú pre užívateľa produkty s vysokou emocionálnou hodnotu (napr. potraviny od miestnych farmárov), ktorých zdroj nie je ochotný meniť, no zároveň by to definovalo skupinu produktov, u ktorých by Amazon mohol dosiahnuť ďalší predaj. Je veľmi pravdepodobné, že okruh tovarov definovaných pre predvídavé doručenie by sa postupne rozširoval.

„**Internet vecí**“, alebo skratene IoT (Internet of Things), označuje „inteligentné objekty“, čiže digitálne pripojené zariadenia, ktoré prijímajú a odosielať dáta. Tieto inteligentné zariadenia spolu komunikujú prostredníctvom interných sietí WLAN, Bluetooth alebo RFID. RFID je skratka pre rádiový frekvenčný identifikáciu: údaje je možné odosielať a prijímať prostredníctvom veľmi malých transpondérov, ktoré obsahujú kód. Tieto mini čipy je možné inštalovať do všetkých druhov zariadení, napríklad do chladničky, hriankovača, elektrickej zubnej kefy alebo termostatu kúrenia.

Prepojené inteligentné produkty a služby môžu pomôcť napríklad pri objednávaní iba tých produktov a množstiev, ktoré sú skutočne nevyhnutné. Jedným z IoT zariadení, ktoré niečo také ponúka, je prístrojové tlačidlo Amazonu tzv. „Dash Button“. Tlačidlo je predkonfigurované pre celý rad výrobkov, okrem rôznych značiek pracích prostriedkov, žiletiek, šampónov, papiera do tlačiarní, krmív pre domáce zvieratá a oveľa viac. Dash tlačidlá by mali visieť v domácnostiach a spúšťať objednávky denných potrieb stlačením jediného tlačidla: od pracieho prostriedku cez krmivo pre mačky až po toaletný papier. Po inštalácii a jeho pripojení k domácej WiFi sa objednávka produktu spustila okamžite stlačením palubnej dosky. Týmto okamihom môžu byť mesiace po výbere produktu.

Digitálni asistenti sú ďalší veľký technologický fenomén. Alexa je digitálny asistent od Amazonu - podobne ako Cortana od Microsoftu alebo Siri od Apple. Je pripojený k internetu a pomocou hlasového ovládania má prístup k službám a informáciám, ktoré užívateľ používa. Napríklad ak si užívateľ kúpi reproduktor Amazon Echo, môže pomocou svojho hlasu:

- počúvať hudbu (Amazon Music, Spotify, Audible, Kindle, Radio)
- získať informácie o premávke alebo počasi

- **nakupovať na Amazone**
- spravovať pripomenutia a schôdzky
- prehrávať správy

Čím viac sa Alexa používa, tým rýchlejšie sa asistent naučí preferencie užívateľa a jazykové návyky. Keďže Alexa je produktom Amazonu, pre nákupy realizované hlasovými príkazmi užívateľa bude produktové portfólio Amazonu východiskovým bodom, čo platí zároveň aj pre predvídavé zásielky.

4.5.2. Vyhodnotenie

Na základe výsledkov prieskumu verejnej mienky konštatujeme nevoľu spoločnosti prijať model predvídavého doručenia ako nový zdroj získavania tovarov domácností. Ako vhodné obdobie **pre implementáciu modelu predvídavého doručenia navrhujeme fázu, kedy budú v spoločnosti plne integrované technológie ako internet vecí a digitálni asistenti, ktorý budú realizovať nákupy namiesto užívateľov.** Nákupy produktov prostredníctvom M2M nepodliehajú emóciám a sú realizované podľa kvantitatívnych, kvalitatívnych, ekonomických, priestorových a časových požiadaviek užívateľa. To vytvorí priestor pre Amazon využiť svoju dominantnú trhovú pozíciu a maximalizovať predaje prostredníctvom nástrojov prediktívnej analýzy a umelej inteligencie – v modeli predvídavého doručenia. Cieľom a očakávaním užívateľa bude „len“ mať takýto produkt k dispozícii, keď ho bude potrebovať. Ušetrený čas od nakupovania môže užívateľ využiť na aktivity s vyššou pridanou hodnotou, napr. prechádzkou s rodinou v prírode.

Záver

Umelá inteligencia je metóda učenia sa z historických údajov pomocou štatistickej analýzy. Údaje o zákazníkoch sú palivom pre umelú inteligenciu, a teda čím efektívnejšie marketing využíva tieto údaje pomocou umelej inteligencie, tým lepšie je možné porozumieť potrebám zákazníka a reagovať na ne spôsobom zameraným na zákazníka. V minulosti boli potrebné údaje zhromažďované s veľkým úsilím. Vďaka veľkým dátam, strojovému učeniu a internetu vecí je teraz jednoduchšie ako kedykoľvek predtým zhromažďovať veľké objemy dát, aby sa dosiahli presné predpovede. S postupujúcou digitalizáciou je prediktívna analytika čoraz dôležitejšia. Či už prostredníctvom aktivít na sociálnych sieťach, nakupovania prostredníctvom digitálnych kontaktných bodov alebo čoraz väčšieho prepojenia koncových zariadení cez internet vecí: Množstvo údajov, ktoré sa v dnešnom svete generuje, je obrovské. Mnoho oblastí použitia veľkých dát využíva tieto obrovské súbory dát. Z toho je možné vyvodiť závery o minulosti a súčasnom stave rôznych faktorov. Na druhej strane oblasť použitia prediktívnej analýzy, ako už názov napovedá, preberá predikciu a výpočet pravdepodobnosti určitých udalostí alebo správania ľudí.

Mnohé z našich nákupných rozhodnutí nie sú založené na logike. Emócie, intuícia, dôvera, komunikačné schopnosti a kultúra - to všetko hrá dôležitú úlohu pri presvedčaní nás k nákupu. Algoritmy umelej inteligencie čoraz viac začleňujú schopnosti identifikovať tieto emócie a vytvárať poznatky, vďaka ktorým je pravdepodobné kupovanie zákazníkov efektívnejšie. Predajcovia intuitívne vytvárajú vzťahy a identifikujú potreby užívateľov ešte predtým, ako užívateľ začne hľadať riešenie. Aj keď sa ľudia môžu niekedy správať na základe presne definovanej logiky, máme vzory správania. Často nakupujeme rovnaké veci, správame sa podobným spôsobom a konáme podľa podobných intuícií. Umelá inteligencia sa učí vzorce kupujúcich s cieľom predvídať budúce nákupné správanie. Cieľom je identifikovať spoločné znaky medzi úspešnými a neúspešnými perspektívami. Prediktívna analytika prináša inteligencii zákazníkov schopnosť ísť nad rámec porozumenia toho, čo sa stalo v minulosti. Poskytuje informácie o tom, prečo sa to stalo, a aké kroky možno podniknúť na zlepšenie budúcej skúsenosti zákazníkov.

Zoznam použitej literatúry

- Ajay Agrawal, J. G. (2018). *Prediction Machines: The Simple Economics of Artificial Intelligence. Anticipatory Shipping*. (07. 08 2020). Dostupné na Internete: <https://www.vallee-partner.de/blog/anticipatory-shipping>
- Attaran, M. A. (12 2018). *Opportunities and Challenges of Implementing Predictive Analytics for Competitive Advantage*. Dostupné na Internete: https://www.researchgate.net/publication/325934828_Opportunities_and_Challenges_of_Implementing_Predictive_Analytics_for_Competitive_Advantage
- Bekker, A. (04. 06 2019). *4 Methoden Der Datenanalyse: ein Überblick für tiefere Einblicke*. Dostupné na Internete: <https://www.scnsoft.de/blog/4-methoden-der-datenanalyse>
- Big Data Analytics In Marketing*. (05. 12 2020). Dostupné na Internete: <https://www.informs.org/ORMS-Today/Public-Articles/October-Volume-40-Number-5/Big-data-analytics-in-marketing>
- Bostrom, N. (dátum neznámy). *Superintelligence: Paths, Dangers, Strategies 1st Edition*. ISBN-13:978-0199678112.
- Coates, A. (13. 12 2016). *Predictive analytics: What are the challenges and opportunities?* Dostupné na Internete: <https://econsultancy.com/predictive-analytics-what-are-the-challenges-and-opportunities/>
- Datenanalytik. (23. 03 2020). *Welche Datenanalyse Trends Prägen Unternehmen In 2020?* Dostupné na Internete: <https://record-evolution.de/welche-datenanalyse-trends-pragen-unternehmen-in-2020/>
- Dave, N. (12. 12 2020). *42 Digital Marketing Trends You Can't Ignore in 2021*. Dostupné na Internete: <https://www.singlegrain.com/digital-marketing-trends-2021>
- Dayan, A. (11. 05 2017). *15 Marketing Analytics Tools You Have To Know About*. Dostupné na Internete: <http://blog.oribi.io/marketing-analytics-tool/>
- Deep Learning, Drei Dinge, die Sie Wissen Sollten*. (09. 09 2020). Dostupné na Internete: <https://de.mathworks.com/discovery/deep-learning.html>
- Galetto, M. (16. 07 2015). *What Is Predictive Analytics*. Dostupné na Internete: <https://www.ngdata.com/what-is-predictive-analytics>
- Galetto, M. (06. 07 2017). *What Is Predictive Marketing*. Dostupné na Internete: <https://ngdata.com/what-is-predictive-marketing>
- Google, P. (dátum neznámy). *Method and system for anticipatory package shipping*. Dostupné na Internete: <https://patents.google.com/patent/US8615473B2/en>
- Kaplan, M. (12. 03 2014). *Anticipatory Shipping: Amazon's Approach to Influencing Purchases*. Dostupné na Internete: <https://www.practicalecommerce.com/Anticipatory-Shipping-Amazons-Approach-to-Influencing-Purchases>
- kolektív., D. L. (2014). *Strategický marketing*. ISBN: 9799089710072.

- Litzel, D. I. (15. 02 2018). *Was ist ein Neuronales Netz*. Dostupné na Internete: <https://www.bigdata-insider.de/was-ist-ein-neuronales-netz-a-686185>
- Loshin, D. (26. 07 2018). *Four challenges to successful predictive analytics models*. Dostupné na Internete: <https://searchbusinessanalytics.techtarget.com/tip/Four-challenges-to-successful-predictive-analytics-models>
- Luber, D.-I. (. (01. 09 2016). *Was ist das Internet of Things?* . Dostupné na Internete: [www.bigdata-insider.de: https://www.bigdata-insider.de/was-ist-das-internet-of-things-a-590806/](https://www.bigdata-insider.de/was-ist-das-internet-of-things-a-590806/)
- Marketing Bedeutung Heute - die Auswirkungen*. (dátum neznámy). Dostupné na Internete: <https://kundenwachstum.de/marketing-bedeutung-heute/>
- Marr, B. (22. 11 2020). *Amazon: Using Big Data to understand customers*. Dostupné na Internete: <https://www.bernardmarr.com/default.asp?contentID=712>
- Nandekar, P. (28. 10 2015). *Anticipatory Shipping- The Game Changer in E-Commerce*. Dostupné na Internete: <https://www.linkedin.com/pulse/anticipatory-shipping-game-changer-e-commerce-pratik-nandekar>
- Pakkanen, L. (29. 07 2019). *8 benefits of Predictive Analytics in Marketing* . Dostupné na Internete: <https://www.nexoya.com/blog/the-benefits-of-predictive-analytics-in-marketing-infographic/>
- predictive Analytics - what it is and why it matters*. (20. 10 2020). Dostupné na Internete: https://www.sas.com/en_us/insights/analytics/predictive-analytics.html
- Robert, K. (29. 06 2018). *Issues with Predictive Analytics*. Dostupné na Internete: <https://www.trustinsights.ai/blog/2018/06/issues-with-predictive-analytics/>
- Santo, A. (27. 12 2018). *What Is Predictive Marketing*. Dostupné na Internete: <https://www.brafton.com/blog/strategy/what-is-predictive-marketing/>
- Shaikh, H. (09. 10 2020). *What Is Predictive Marketing? Types, Working, Uses, Top Tools, and More*. Dostupné na Internete: <https://martechlive.com/predictive-marketing-types-tools-and-more>
- Simple Grain Team. (28. 11 2020). *Why Digital Marketing Analytics Matter To Your Business*. Dostupné na Internete: <https://www.singlegrain.com/blog-posts/analytics/why-digital-marketing-analytics-matter/>
- Steinhaus, I. (02. 03 2017). *IT-Zoom*. Dostupné na Internete: Wenn der Mülleimer im IoT das Einkaufen lernt: <https://www.it-zoom.de/mobile-business/e/wenn-der-muelleimer-im-iot-das-einkaufen-lernt-16149/>
- The Data Company. (12. 05 2020). *6 tips for overcoming Predictive Analytics challenges*. Dostupné na Internete: <https://thedatacompany.com/6-tips-for-overcoming-predictive-analytics-challenges/#:~:text=Like%20most%20software%20or%20tools%2C%20predictive%20analytics%20can,around%20ensuring%20that%20these%20issues%20do%20not%20occur.>
- Údaje z registra firmy*. (dátum neznámy). Dostupné na Internete: [ekariera.sk: https://www.ekariera.sk/firmy/amazon](https://www.ekariera.sk/firmy/amazon)

Vladimír Kvasnicka, L. J. (04. 05 2020). *Úvod do teórie neurónových sietí*. Dostupné na Internete: http://www.2.fiit.stuba.sk/~kvasnicka/Free%20books/Uvod%20do%20teorie%20neuronovych%20sieti_all.pdf

Was Ist Ein Neuronales Netz, Drei Dinge, Die Sie Über Neuronale Netze Wissen Sollten. (03. 11 2020). Dostupné na Internete: <https://de.mathworks.com/discovery/neural-network.html>

Wuttke, L. (10. 09 2020). *Künstliche Neuronale Netzwerke: Definition, Einführung, Arten und Funktion*. Dostupné na Internete: <https://datasolut.com/neuronale-netzwerke-einfuehrung>