

UNIVERZITA KARLOVA

FAKULTA SOCIÁLNÍCH VĚD

Institut komunikačních studií a žurnalistiky

Katedra marketingové komunikace a public relations

Diplomová práce

2025

Bc. Josef Němeček

UNIVERZITA KARLOVA

FAKULTA SOCIÁLNÍCH VĚD

Institut komunikačních studií a žurnalistiky

Katedra marketingové komunikace a public relations

**Hyper-personalizace v reálném čase: Využití generativní
AI pro cílení reklamy podle vizuálního kontextu**

Diplomová práce

Autor práce: Bc. Josef Němeček

Studijní program: Strategická komunikace

Vedoucí práce: Mgr. Ing. Marek Vranka

Rok obhajoby: 2025

Prohlášení

1. Prohlašuji, že jsem předkládanou práci zpracoval samostatně a použil jen uvedené prameny a literaturu.
2. Prohlašuji, že práce nebyla využita k získání jiného titulu.
3. Souhlasím s tím, aby práce byla zpřístupněna pro studijní a výzkumné účely.
4. Při přípravě této práce autor použil ChatGPT za účelem stylistické korektury. Po použití tohoto nástroje autor obsah podle potřeby zkontroloval a upravil a přebírá plnou odpovědnost za obsah publikace.

V Praze dne 27. 4. 2025

Bc. Josef Němeček

Bibliografický záznam

Němeček, J. (2025). *Hyper-personalizace v reálném čase: Využití generativní AI pro cílení reklamy podle vizuálního kontextu* [Diplomová práce, Univerzita Karlova]. Digitální repozitář Univerzity Karlovy.

Rozsah práce: 142 853 znaků

Abstrakt

Tato diplomová práce se zabývá návrhem a ověřením systému dynamické hyper-personalizace reklam ve fyzickém retailu s využitím generativní umělé inteligence. Teoretická část shrnuje vývoj marketingové personalizace, její psychologické mechanismy a mapuje relevantní technologie AI. Praktická část se zaměřuje na návrh architektury systému kombinující percepční, inferenční a generativní vrstvu a na jeho nasazení v rámci terénního experimentu ve čtyřech kosmetických prodejnách. Výsledky terénního experimentu ukázaly, že hyper-personalizovaná reklama prodlužuje dobu zaujetí zákazníků, zatímco vliv na pravděpodobnost nákupu nebyl potvrzen. Práce přispívá k empirickému poznání vlivu AI personalizace v off-line prostředí a navrhuje směry pro další výzkum.

Abstract

This thesis focuses on the design and validation of a dynamic hyper-personalization advertising system in physical retail environments using generative artificial intelligence. The theoretical part summarizes the development of marketing personalization, its psychological mechanisms, and maps relevant AI technologies. The practical part concentrates on the design of a system architecture combining perceptual, inferential, and generative layers, and its deployment within a field experiment conducted in four cosmetic stores. The results of the field experiment showed that hyper-personalized advertising increases customer engagement time, while the effect on purchase probability was not confirmed. The thesis contributes to the empirical understanding of AI-driven personalization in offline environments and proposes directions for future research.

Klíčová slova

umělá inteligence, generativní AI, hyper-personalizace, marketingová personalizace, dynamická reklama, retail marketing, in-store, velké jazykové modely, experiment, LLM, AI

Keywords

artificial intelligence, generative AI, hyper-personalization, marketing personalization, dynamic advertising, retail marketing, in-store marketing, experiment, large language models, LLM, AI

Title

Real-Time Hyper-Personalization: Leveraging Generative AI for Ad Targeting Based on Visual Context

Poděkování

Tímto chci složit velké poděkování a obdiv Ing. Petrovi Morávkovi a Ing. Janu Mazochovi, bez jejichž bezmezného úsilí by byla implementace technické části práce výrazně složitější. Můj dík také patří Ing. Ondrovi Šantorovi za spoluvedení projektu, na jehož základě tato práce mohla vzniknout, a nakonec samozřejmě mému vedoucímu práce Mgr. Ing. Markovi Vrankovi za cenné poznámky k designu experimentu.

Obsah

Obsah	8
Úvod	8
1. Teoretická část	10
1.1. Personalizace marketingové komunikace	10
1.1.1. Definice pojmů	10
1.1.1.1. Customizace, 1:1 marketing, hyper-personalizace	11
1.1.1.2. Personalizace jako proces	13
1.1.2. Evoluce marketingové personalizace	15
1.1.2.1. 1860s–1980s – Průmyslová revoluce a masová komunikace	15
1.1.2.2. 1990s – Segmentace a příchod internetu	16
1.1.2.3. 2000s – Nástup digitálních kanálů a personalizačních algoritmů	17
1.1.2.4. 2010s – Doba datová a nástup sociálních médií	18
1.1.2.5. 2020s – Pokročilá analytika a umělá inteligence	19
1.2. Psychologické mechanismy vnímání personalizace	20
1.2.1. Definice hlavních psychologických mechanismů	20
1.2.1.1. Priming a preatentivní procesy	20
1.2.1.2. Retikulární aktivační systém (RAS)	21
1.2.1.3. Heuristiky a zkreslení	22
1.2.1.4. Elaboration Likelihood Model (ELM)	23
1.2.1.5. Uses and Gratifications Theory (UGT)	24
1.2.2. Psychologické hranice a personalizační paradox	25
1.2.2.1. Hranice relevance a invazivitou	25
1.2.2.2. Kontextuální rozdíly ve vnímání personalizace	27
1.3. AI, strojové učení, GenAI a jejich využití v personalizaci	28
1.3.1. Definice pojmů umělé inteligence	28
1.3.1.1. Umělá inteligence (Artificial Intelligence)	29
1.3.1.2. Strojové učení (Machine Learning)	31
1.3.1.3. Hluboké učení (Deep Learning)	33

1.3.1.4.	Počítačové vidění (Computer Vision)	34
1.3.1.5.	Zpracování přirozeného jazyka (NLP)	35
1.3.1.6.	Velké jazykové modely (LLM) a generativní AI	37
1.4.	Data – význam, typologie a zdroje	39
1.4.1.	Typologie dat podle segmentační logiky	40
1.4.1.1.	Geografická segmentace	40
1.4.1.2.	Demografická segmentace	41
1.4.1.3.	Behaviorální segmentace	42
1.4.1.4.	Psychografická segmentace	42
1.4.1.5.	Ideologická segmentace	43
1.4.1.6.	Kulturní segmentace	44
1.4.1.7.	Kontextuální segmentace	44
1.4.1.8.	Segmentace podle benefitů	45
1.4.1.9.	Více proměnná segmentace	45
1.4.2.	Sběr a struktura dat	46
2.	Praktická část	48
2.1.	Návrh systému pro dynamickou hyper-personalizaci	49
2.1.1.	Popis architektury systému	49
2.1.1.1.	Percepční vrstva	49
2.1.1.2.	Inferenční vrstva	50
2.1.1.3.	Generativní vrstva	52
2.1.1.4.	Výstupní vrstva	53
2.2.	Experimentální ověření systému v retailu	55
2.2.1.	Definice výzkumného problému	55
2.2.2.	Cíle výzkumu a stanovení hypotéz	56
2.2.3.	Metodologie výzkumu	58
2.2.3.1.	Design výzkumu a experimentální uspořádání	58
2.2.3.2.	Popis výzkumného souboru	61
2.2.3.3.	Předzpracování dat	62
2.2.3.4.	Příprava reklamních stimulů	64
2.2.3.5.	Sběr dat a měřené proměnné	65
2.2.4.	Metody analýzy	67

2.3.	Vyhodnocení výzkumu.....	70
2.3.1.	Vyhodnocení vlivu hyper-personalizace na zaujetí (H1)	70
2.3.2.	Vyhodnocení vlivu hyper-personalizace na nákupní chování (H2)	72
2.3.3.	Vztah mezi zaujetím reklamou a nákupním chováním (H3).....	73
2.3.4.	Vliv hyper-personalizace na obecné nákupní chování (H4).....	75
2.3.5.	Moderující efekty demografie (VO1).....	77
2.3.5.1.	Vliv věku a pohlaví na dobu zaujetí	77
2.3.5.2.	Vliv věku na obecné nákupní chování.....	79
2.3.5.3.	Vliv pohlaví na obecné nákupní chování.....	80
2.4.	Diskuse a shrnutí	83
2.5.	Limity práce a doporučení pro další výzkum	86
	Závěr.....	88
	Summary	89
	Použitá literatura.....	91
	Přílohy	106

Úvod

Personalizace marketingu se v posledních letech stala jedním z klíčových trendů v oboru. Od tradičního marketingu, jenž oslovoval masové publikum jednotným sdělením, se postupně přešlo k cíleným kampaním šitým na míru specifickým segmentům zákazníků. Výzkumy potvrzují, že personalizovaný marketing má významný pozitivní dopad na obchodní výsledky. Například studie publikovaná v Harvard Business Review uvádí, že pokročilá personalizace má potenciál snížit náklady na akvizici zákazníka až o 50 %, zvýšit tržby o 5–15 % a zlepšit návratnost marketingových investic o 10–30 % (Ariker et al., 2015). To, že vnímané výhody personalizace nejsou jednostranné, dokazují i studie zkoumající zákaznickou perspektivu. Podle nich 71 % spotřebitelů požaduje od firem personalizovaný obsah a 67 % zákazníků dokonce pociťuje frustraci, pokud nabídka není přizpůsobena jejich potřebám (Arora et al., 2021). Personalizace se tak stává nezbytnou součástí marketingové strategie firem a její význam nadále roste.

S nástupem nových nástrojů umělé inteligence jako generativní umělé inteligence a velkých jazykových modelů (LLM) dochází k dalšímu zásadnímu posunu v úrovni personalizace. Moderní technologie dnes umožňují optimalizovat a zdrobnit marketingovou komunikaci až na individuální úroveň, kdy je každý zákazník oslovován zvlášť skrze takzvanou hyper-personalizaci. Právě schopnost automatizace a škálovatelnosti personalizovaného obsahu umožňuje firmám otevřít firmám možnost přenést efekt personalizované komunikace také do fyzického prostředí, kde dosud dominovaly standardizované formy oslovování zákazníků. Nové nástroje jako generativní AI umožňují, aby i v off-line retailu bylo možné oslovit každého návštěvníka dynamicky na základě jeho aktuálního kontextu a charakteristik.

Tato diplomová práce si klade za cíl tyto změny v marketingové personalizaci nejen teoreticky popsat, ale také demonstrovat jejich promítnutí do praxe. Hlavní zaměření práce je návrh, realizace a experimentální ověření systému pro dynamickou hyper-personalizaci reklamního obsahu v kamenném obchodě pomocí nástrojů umělé inteligence. Ačkoli základní princip dynamické hyper-personalizace sdělení zůstává zachován, oproti původnímu záměru práce došlo k posunu v sektoru aplikace této technologie. Zatímco

původní teze zamýšlela její využití v politickém marketingu, samotný výzkum byl nakonec realizován v prostředí fyzického retailu v soukromém sektoru. Tento odklon byl motivován vzniklou příležitostí testovat tuto technologii v rámci terénního experimentu v prostředí reálných prodejen, což bylo vyhodnoceno jako cennější výzkumná příležitost. Tato práce je rozdělena do dvou hlavních částí: teoretické a praktické.

Teoretická část byla navržena tak, aby tvořila silný základní rámec pro pochopení technologií a mechanismů, na kterých bude tato práce stavět. Nejprve systematicky rozebírá a definuje základní pojmy spojené s personalizací marketingové komunikace, které posléze zasazuje do historického kontextu. Následně je věnována pozornost psychologickým mechanismům a limitům personalizace, na které je referováno v praktické části práce, a popisu relevantních technologií umělé inteligence, jejichž pochopení je stěžejní pro návrh architektury hyper-personalizačního systému. Důležitým aspektem této práce je také rozdělení, definice a praktické využití segmentačních dat, které jsou rozebrány v poslední kapitole teoretické části.

Praktická část práce je strukturována do tří navazujících celků. První část je zaměřena na tvorbu architektury systému dynamické hyper-personalizované reklamy. Tento systém propojuje percepční snímání zákazníků pomocí kamerových senzorů, inferenční analýzu vizuálních dat za účelem vyhodnocení demografických a behaviorálních charakteristik, a následnou generaci personalizovaného reklamního obsahu v reálném čase prostřednictvím velkého jazykového modelu. Ve druhé části praktické části práce byl tento systém implementován a nasazen do reálného prostředí čtyř kamenných kosmetických. Tato část podrobně popisuje jak technické aspekty implementace, tak specifické podmínky prostředí, které mohly ovlivnit fungování systému a sběr dat. Součástí této části byl také návrh experimentálního designu, jehož cílem bylo kvantitativně testovat efektivitu hyper-personalizace v porovnání s generickým reklamním sdělením. Ve finální části práce probíhá samotné vyhodnocení experimentu, pro které byly analyzovány klíčové metriky jako délka zaujetí a nákupní chování.

1. Teoretická část

1.1. Personalizace marketingové komunikace

1.1.1. Definice pojmů

Personalizace se už jen dle svého názvu zaobírá přizpůsobením komunikace, nabídek, služeb či produktů potřebám a preferencím spotřebitelů na osobní úrovni, nicméně v literatuře najdeme hned několik definic tohoto pojmu, které se navíc vyvíjely s časem. Od 80. let lze sledovat posun od mezilidsky orientovaného pojetí směrem k více holistickému technicko-strategickému uchopení pojmu. Již v 80. letech definovali Surprenant a Solomon (1987) personalizaci jako jakékoli chování vyskytující se v interakci, které má přispět k individualizaci zákazníka v oblasti služeb. Začátkem 21. století se s nástupem technologií objevuje důraz na digitální platformy a definice se zaměřují na technologické zprostředkování personalizace (Fan & Poole, 2006; Murthi & Sarkar, 2003). V druhé dekádě lze sledovat zaměření akademiků na datově orientované pojetí personalizace, kdy autoři jako Zhang (2011) zdůrazňují důležitost využívání zákaznických dat k optimalizaci komunikace. Nejnovější definice například od Mehmood a spol. (2022) pak personalizaci chápou jako komplexní přístup, který integruje technologické, behaviorální i strategické složky a reflektuje její roli v celé hodnotové nabídce firmy.

Často citovaní autoři Arora a spol. (2008) na personalizaci nahlíží jako na *přístup firmy, která na základě dříve získaných zákaznických dat iteruje svůj marketingový mix tak, aby byl co možná nejrelevantnější pro jejich zákazníka*. Jako širší pojem, který se podepisuje do celé marketingové strategie firmy, chápe personalizaci Aguiere a spol. (2015), kteří ji definují jako *zákaznický orientovanou marketingovou strategii, jejíž cílem je poskytnout správné sdělení správné osobě ve správný čas*. Personalizace v tomto smyslu rozvíjí tradiční marketingový mix směrem k individuálním požadavkům zákazníků, což bylo s rozvojem databázového marketingu a CRM vnímáno jako cesta, jak překonat omezení hromadné uniformní komunikace. Někteří z autorů vidí personalizaci spíše jako samostatný proces. Například Sunikka a Bragge (2012) popisují personalizaci jako *proces zajištění relevantní nabídky produktů a služeb správným zákazníkům ve správném čase a v správném kontextu*.

Ačkoli je tato definice vizuálně líbivá, nabízí jen velmi omezený kontext pro jasnou diferenciaci personalizace od podobných pojmů.

Definice personalizace, o kterou se bude tato práce opírat, je definice použitá Jari Vesanenem (2007). Tato definice byla vybrána pro své poměrně úzké zaměření, které sdílí i tato studie. *Personalizace je využití technologií a informací o zákaznících k přizpůsobení interakcí mezi podnikem a každým jednotlivým zákazníkem. S využitím informací o zákazníkovi, které byly buď získány dříve, nebo získány v reálném čase, je výměna mezi stranami upravena tak, aby odpovídala deklarovaným potřebám zákazníka a také potřebám, které podnik vnímá na základě dostupných informací o zákazníkovi.*

1.1.1.1. Customizace, 1:1 marketing, hyper-personalizace

Princip personalizace je, jak akademiky, tak experty, často nesprávně zaměňován jinými termíny jako individualizace (Riemer & Totz, 2001), segmentace (Smith, 1956), customizace, profilování a one-to-one marketing (Peppers & Rogers, 1993). Všechny pojmy se vztahují k individuálnímu přizpůsobení marketingové nabídky zákazníkovi, avšak při podrobnějším vymezení lze mezi nimi rozlišovat.

Arora a spol. (2008) například vnímají 1:1 a masovou komunikaci jako dva protipóly na škále segmentace a personalizaci a customizaci pak jako dvě odlišné podformy marketingu 1:1 (viz. Schéma 1). Pojmy personalizace a customizace se pak liší převážně v míře zákaznickém zapojení. Zatímco personalizace podle nich nastává, když prodejce sám na základě dříve sesbíraných zákaznických dat rozhodne, jaký kontaktní bod s jakou nabídkou je pro konkrétního zákazníka nejvhodnější, customizace naproti tomu vyžaduje iniciativu od samotného zákazníka. Ten se proaktivně zapojuje do specifikací produktových nebo komunikačních prvků tak, aby odpovídaly jeho vlastním preferencím (Bleier et al., 2018). V procesu personalizace je pro identifikaci a uspokojení potřeby zákazníků potřeba minimálního vynaložení úsilí z jejich strany (Tam & Ho, 2006). Rozdíl mezi customizací a personalizací můžeme hledat také v stylu získávání dat o uživatelích. V případě customizace

data poskytuje proaktivně samotný uživatel v rámci explicitní interakce. Typicky může jít o výběr jeho preferované barvy při tvoření vlastních tenisek Nike (Trefis Team, 2015), volba výkonu procesoru při výběru notebooku, nebo tvorba salátu dle preferovaného složení. Při personalizaci jsou naopak data získávána nepřímou a často pasivně, a to například měřením chování zákazníků (např. nákupní historie, interakce s obsahem, reakce na kampaně), nebo dalších atributů (např. demografie, lokace, zařízení, ale i vizuální atributy).

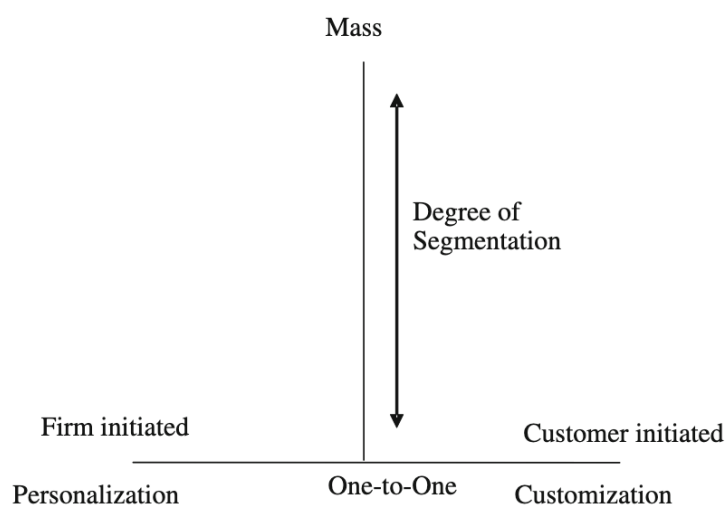


Schéma 1– Znárodnění vztahu pojmů (Arora et al., 2008)

Za pomyslný ideál, ke kterému se personalizace snaží přiblížit, je právě marketing 1:1, také známý pod pojmem hyper-personalizace. Ta představuje extrémní formu segmentace, při níž je cílový segment zredukován na jediného, konkrétního zákazníka, jehož potřeby, zájmy a kontext určují podobu celého marketingového mixu firmy (Arora et al., 2008). Podle Davenporta (2023) je největší limitující faktor personalizace nedostatek kvalitních dat a personalizačních technologií, které jsou právě pro docílení hyper-personalizace klíčové.

1.1.1.2. Personalizace jako proces

Pro lepší projekci personalizace do novodobého marketingu můžeme personalizaci konceptualizovat jako proces. S tímto pojetím personalizace přišli už Peppers a Rogers (1993), kteří byli taky jedni z prvních, kteří tento proces pokusili definovat. Podle nich se dá rozdělit do čtyř fází: identifikace potenciálních zákazníků, určení jejich potřeb a jejich hodnoty pro nás jako společnost, interakce se zákazníky za účelem získání informací a přizpůsobení produktů, služeb a komunikace jednotlivým zákazníkům. Ačkoli toto pojetí není daleko od moderního konceptu personalizace, autoři na tento proces dívali ještě optikou doby před digitální, kdy personalizaci chápali jako statický prvek.

Aktuálnější pojetí procesu personalizace sdílí například Kushnarevych a Kollárová (2023), kteří představují personalizaci v marketingu jako dynamický proces, během něhož je marketingové sdělení nebo zákaznický zážitek přizpůsobován konkrétní osobě na základě jejího chování a preferencí. Autoři v této studii rozdělili proces personalizace na 4 základní elementy a na interakce mezi nimi (viz. Schéma 2). Personalizační proces podle nich začíná (1.) získáváním dat především o chování zákazníků (např. nákupní historie, interakce s obsahem, reakce na kampaně) a dalších atributů (např. demografie, lokace, zařízení, ale i vizuální atributy). Důležitá je schopnost zachytit jak strukturovaná, tak nestrukturovaná data z různých kanálů. (2.) Tato data jsou následovně agregována, kombinována a analyzována pomocí analytických nástrojů nebo algoritmů umělé inteligence. Cílem je odhalit preference zákazníků, predikovat jejich chování a segmentovat je do co nejrelevantnějších kategorií – případně až na úroveň jednotlivce. (3.) Na základě analýzy je třeba definovat, jak bude logika personalizace vypadat, a tedy jaký obsah komu a kdy doručit. Zde hraje roli rozhodovací algoritmus, který kombinuje vstupy z analytiky a uplatňuje pravidla nebo prediktivní modely pro personalizaci. (4.) Po stanovení personalizační logiky přichází na řadu samotné vytvoření individuálně přizpůsobeného sdělení. V kontextu využití AI se může jednat o automatizované generování textu (např. pomocí velkých jazykových modelů (LLM)), výběr nejvhodnějšího vizuálu, produktového doporučení nebo jiná personalizace marketingového mixu. (5.) Zásadní pro personalizaci je také načasování a výběr správného komunikačního kanálu, přes který se personalizovaný obsah doručuje. V kontextu digitální personalizace se typicky jedná o e-mail, sociální síť, webovou stránku, notifikace. Personalizaci ale lze provádět i ve fyzickém prostředí například skrze věrnostní programy či digitální nosiče

v místě prodeje. (6.) Po doručení sdělení je klíčové měření a vyhodnocení reakce zákazníka (např. míra prokliku, zapojení, nákup, doba sledování, emoce). Tato data jsou následně zpětně začleněna do systému personalizačního procesu a celý proces se iterativně optimalizuje.

Definice personalizace jako procesu ji vymezuje vůči pojetí jako pouze statické úpravy nabídky, a naopak na ni umožňuje nahlížet jako na vyvíjející se mechanismus, který reaguje na nová data a mění se zákaznické preference. Jde tedy o proces vytváření na míru šité




Schéma 2 – Proces personalizace (Vesanen & Raulas, 2006)

formy komunikace, jehož účinnost se odvíjí od přesnosti a relevance dat, z nichž vychází. Cílem tohoto procesu je zvýšit pravděpodobnost, že se zákazník se sdělením ztotožní, bude jej vnímat jako užitečné a relevantní, a tedy s větší pravděpodobností na něj zareaguje.

1.1.2. Evoluce marketingové personalizace

I přesto, že je pojem personalizace v kontextu marketingové komunikace systematicky zkoumán až od 20. století, samotný princip upravování nabídky dle potřeb zákazníka byl využíván od počátků obchodu. V době před industriální revolucí probíhal kontakt mezi prodejcem a zákazníkem nejčastěji na osobní úrovni a opakovaně. Prodejce tak mohl upravovat svou komunikaci na míru jednotlivým zákazníkům, a to nejen podle jejich jména, ale také podle preferencí, minulých nákupů, potřeb či finančních možností. Nabídka produktů a služeb tak často nebyla vytvářena plošně, ale právě „na míru“ jednotlivým zákazníkům. Tento přímý kontakt, nazýván jako vztahový marketing (*relationship marketing*), vede podle Setha a Parvatiyara k lepšímu porozumění, kooperaci a silnějšímu vztahu k produktu (1995).

V tomto období tedy nebyla personalizace v komunikaci vnímána jako strategická volba, ale spíše jako přirozený důsledek omezeného velikosti trhu a nízkého stupně škálovatelnosti. Vztahy byly vedeny bez prostředníků či formalizované marketingové analýzy. Zákazník byl jedinečný a jeho jedinečnost byla samozřejmou součástí obchodní interakce. Personalizace v komunikaci existovala defaultně – nikoliv jako cílený nástroj optimalizace konverzí, ale jako součást každodenního lidského kontaktu. Ukotvení konceptu personalizace v historickém kontextu je důležité pro pochopení jeho evoluce přicházející v digitální době. Ačkoli se na první pohled může zdát, že jde o nový marketingový fenomén, jedná se spíše o technologicky zprostředkovanou adaptaci dříve běžné obchodní reality.

1.1.2.1. 1860s–1980s – Průmyslová revoluce a masová komunikace

Výrazná změna přišla společně s průmyslovou revolucí, v rámci které se začala uplatňovat orientace na produkci. Robert J. Keith datuje toto zlomové období mezi léta 1860 a 1930 (1960). V této době se centrem zájmu staly snahy o navyšování efektivity a objemu produkce, a to zejména z důvodu, že poptávka trhu stále přesahovala jeho nabídku. Zatímco v předindustriální éře převládal osobní a vztahový marketing, rozvoj masové výroby vedl k potřebě masového odbytu a tím i k rozvoji masové komunikace. Oddělení osobního vztahu

výrobce a spotřebitele vedlo k poklesu personalizace a obchodníci začali hledat způsoby, jak oslovit co nejširší publikum co nejefektivnějším způsobem. Trh začal být chápán jako homogenní masa a marketing jako jednosměrná komunikace k zákazníkovi (Jones & Shaw, 2002).

Přesto se i v tomto období dají pozorovat první systematické pokusy o personalizaci formou přímého marketingu pomocí dopisů (Dangi & Malik, 2017). I přes poměrně nízkou úroveň personalizace formou přímého oslovení jménem, dosáhly podle studie magazínu Time dopisy šestinásobné míry odpovědí oproti dopisům generickým (Reed, 1949). Navzdory tomuto počátečnímu úspěchu zůstávala personalizace před nástupem počítačů nákladná a obtížná. S koncepční změnou v marketingové teorii přišel v druhé polovině 20. století Wendell R. Smith, který jako první systematicky popsal a obhájil koncept segmentace trhu. Smith ve své práci práci argumentuje, že trh není jen homogenní masou jak se předpokládalo, ale spíše součin různorodých segmentů spotřebitelů s odlišnými potřebami a preferencemi (Smith, 1956). Touto myšlenkou položil základy moderního marketingového přístupu a nasměroval ho svým způsobem zpět k osobnějším vztahům mezi prodejcem a zákazníkem.

1.1.2.2. 1990s – Segmentace a příchod internetu

Konec 20. století vedl k výraznému posunu v možnostech personalizace a segmentace, a to především díky nástupu informačních technologií a internetu. Přechod k přesnější segmentaci a komunikaci byl možný především díky nástupu databázových systémů a nových komunikačních kanálů. Velkým milníkem bylo spuštění první masové e-mailové služby Hotmail, která v roce 1996 otevřela marketingovým specialistům přímý přístup ke svým zákazníkům. Stejně jako v případě personalizace dopisů se i zde nejprve začala využívat velice jednoduchá personalizace skládající se z osobního oslovení zákazníků jménem bez komplexnější úpravy obsahu samotného e-mailu. Personalizace se začala objevovat nejen v podobě přímého marketingu, ale i v podobě rané online reklamy – včetně prvních bannerových formátů, jejichž správu zefektivnila například platforma DoubleClick (Murár, 2023). Akademici začali pro tuto změnu v marketingové praxi přicházet s různými

termíny jako 1:1 marketing či personalizovaný marketing, které se často významově překrývaly, ale v různých iteracích zůstávají používané dodnes (Peppers & Rogers, 1993; Surprenant & Solomon, 1987). Právě Surprenant & Solomon (1987) jako první definovali personalizaci jako jakékoli chování vyskytující se v interakci, které má přispět k individualizaci zákazníka v oblasti služeb.

1.1.2.3. 2000s – Nástup digitálních kanálů a personalizačních algoritmů

Na začátku 21. století byl přístup k marketingové personalizaci zásadně ovlivněn, a to jak v teoretickém, tak technickém smyslu. Klíčovou roli sehrál nástup internetu a jeho rychlá adopce. Začaly vznikat elektronické obchody, nové digitální kanály a platformy, které odemkly dosud nemožnou úroveň personalizace. Tento pokrok se promítl i na zájem akademické komunity, která se odklonila od výzkumu analogových forem personalizace směrem k jejich virtuálním formám např. profilování zákazníků, doporučovací systémy, systémy podpory rozhodování a neuronové sítě (Chandra et al., 2022).

V tomto období se také začaly poprvé objevovat významnější aplikace personalizačních algoritmů do reálného prostředí, které přinesly empirická data o efektivitě personalizace. Na začátku roku 2000 se vyvinuly reklamní formáty bannerů, což podnítilo rychlý rozvoj webové analytiky. Kolem roku 2007 se objevil koncept remarketingu, který zobrazoval cílené reklamy uživatelům, kteří opustili webovou stránku, aniž by dokončili transakci (Lambrecht & Tucker, 2013).

V roce 2003 byl zaměstnanci Amazonu v časopise *Internet Computing* publikován článek, který popisoval vývoj algoritmu zajišťující doporučení produktů na základě minulého nákupního chování a preferencí (Linden et al., 2003). Po představení sekcí „doporučeno pro vás“ a „zákazníci také nakoupili“ podle výzkumníků výrazně vzrostla míra prokliku a konverze v porovnání s necíleným obsahem, jako reklamní bannery a seznamy nejprodávanějších produktů. V roce 2006 vyhlásila společnost Netflix soutěž o návrh algoritmu na doporučování filmů, který by překonal tehdy využívaný systém Cinematch.

Význam, který Netflix přikládal personalizaci, dokládá i fakt, že vítěz soutěže měl získat odměnu jeden milion amerických dolarů (Bennett et al., 2007).

1.1.2.4. 2010s – Doba datová a nástup sociálních médií

Pakliže minulé období dávala důraz především na technologický rozvoj digitálních kanálů, po roce 2010 se pozornost upřela na data, která z těchto kanálů proudila. Firmy začaly systematicky využívat jak strukturovaná, tak nestrukturovaná data (viz. kap. Data – význam, typologie a zdroje) z různých interních i externích zdrojů ke generování individuálních doporučení, nabídek a obsahů. To přineslo automatizovanou a datově řízenou personalizaci, zapojení strojového učení a prediktivní analytiky (Wedel & Kannan, 2016).

Personalizace byla v tomto období zásadně ovlivněna prudkým rozvojem mobilního internetu a masovým rozšířením chytrých telefonů. Internet se stal všudypřítomným a prostupoval do každodenního života čím dál tím většího počtu lidí. Už v roce 2015 bylo podle dat Hyde a spol. (2024) na světě přes 3 miliardy aktivních uživatelů internetu. Mobilní telefony začaly plnit roli tichého sběrače dat, zaznamenávajícího vzorce chování uživatelů, preference i kontext uživateleova prostředí. V kombinaci s dynamickým rozvojem sociálních sítí vznikl ekosystém, v němž firmy dokáží vytvářet komplexní profily zákazníků, spouštět přesně cílené kampaně a vyhodnocovat jejich reakci na ně. Důležitost role zákaznických profilů a výrazný posun v efektivitě personalizace dokládají i případy z praxe. V roce 2016 odhalil Netflix, že jeho doporučovací systém řízený AI ušetří společnosti více než 1 miliardu dolarů ročně, a to především díky zvýšené míře spokojenosti a retence předplatitelů (Gomez-Uribe & Hunt, 2016). Tato metrika ukazuje, jak velkou roli začala personalizace hrát v obchodních modelech digitálních platforem.

I přes zjevnou vlnu personalizačního nadšení začaly sílit i hlasy vznášející etické a společenské otázky v oblasti datového soukromí (Acquisti et al., 2012; Aguirre et al., 2015). Zásadní roli ve vývoji vnímání datového soukromí sehrály události, které výrazně otráslly důvěrou veřejnosti v práci s osobními daty. Mezi jednu z nejvýznamnějších patří kauza

společnosti Cambridge Analytica, která v rámci prezidentské kampaně v USA v roce 2016 nelegálně využila data stovek milionů uživatelů Facebooku k vytváření detailních psychologických profilů na základě pětifaktorového modelu osobnosti (Concordia, 2016; Costa & McCrae, 1992). Zakladatel Cambridge Analytica Alexander Nix uvedl, že se jí z různých zdrojů podařilo nasbírat 5000 datových bodů na většinu z 230 milionů amerických voličů, na základě kterých následně spustila přes 10 000 variant reklam navržených tak, aby oslovily voliče na základě jejich individuálních rysů a ovlivnily jejich volební chování (OMR, 2017). Medializace tohoto případu v roce 2018 vyvolala mezinárodní pobouření a přispěla ke zvýšení tlaku na regulaci zpracování dat. V témže roce vstoupilo v Evropské unii v platnost Obecné nařízení o ochraně osobních údajů (GDPR), které nastavilo nové standardy pro zacházení s daty a posílilo práva jednotlivců v digitálním prostoru.

1.1.2.5. 2020s – Pokročilá analytika a umělá inteligence

Současné období označila společnost McKinsey ve svém reportu jako novou etapu pro marketingovou personalizaci (Stein et al., 2025). Naráží tak na skokový vývoj v oblasti generativní umělé, který umožňuje přerod z klasické datové personalizace na automatizovatelnou a tedy i škálovatelnou hyper-personalizaci, která dokáže personalizovaný obsah v reálném čase nejen doručovat, ale i vytvářet.

Vedle schopnosti škálovat personalizaci prostřednictvím generativní umělé inteligence přináší současný vývoj i změnu samotného přístupu k tvorbě a doručování personalizovaného obsahu. Firmy se přesouvají od statických segmentačních modelů k dynamickým, AI-řízeným rozhodovacím procesům, které umožňují reagovat na potřeby zákazníků v reálném čase. Jak uvádí McKinsey (Stein et al., 2025), díky kombinaci vylepšené analytiky, pokročilé segmentace a generativní AI mohou firmy nejen lépe cílit propagační nabídky, ale i tvořit personalizovanou komunikaci s vhodným tónem, stylem a vizuály podle individuálních preferencí zákazníků.

1.2. Psychologické mechanismy vnímání personalizace

Již od začátku obchodu existovala přirozeně i touha po pochopení zákaznického chování a rozhodování. Tato touha byla umocněna přerodem formy nákupu čistě z kamenného obchodu na dynamičtější omnichannel (multikanálový) prodej. Pro odpovědi se výzkumníci obrátili na teorie lidské psychologie, kterými se chování spotřebitelů v nákupním prostředí dá popsat a které vysvětlují účinnost personalizace. Následující kapitola rozebírá hlavní psychologické mechanismy s dopadem na vnímání personalizované komunikace.

1.2.1. Definice hlavních psychologických mechanismů

1.2.1.1. Priming a preatentivní procesy

První interakce mezi vjemem a lidským mozkiem probíhá na podprahové úrovni, ale už v tento moment můžou být částečně zpracovány a na příjemce sdělení působit (Eysenck & Keane, 2008). Tento efekt, který probíhá v rámci preatentivních (předpozornostních) procesů nazýváme priming. Priming obecně označuje jev, kdy expozice prvního podnětu ovlivní vnímání podnětu následujícího, aniž by si toho byl příjemce vjemu vědom. Výzkum primingu se datuje už do 60. let 20. století, nicméně do praxe se jeho techniky dostaly až v polovině 80. let 20. století, kdy se začaly objevovat v byznysu a marketingu.

Priming lze rozdělit na různé typy – například sémantický, behaviorální či afektivní. Každý z těchto typů může být jiným způsobem využit v personalizované komunikaci. V experimentu Fitzsimonse a spol. (2008) se ukázalo, že i pouhé vystavení logu značky může podvědomě aktivovat mentální asociace a ovlivnit následné chování. Účastníci, kteří byli krátce vystaveni logu značky Apple, která bývá spojována s kreativními hodnotami, projevili vyšší míru originality v kreativním úloze než ti, kteří viděli logo IBM, asociované spíše s precizností. Tento behaviorální priming ukazuje, že značka může svým vizuálním symbolem navodit u zákazníka konkrétní psychologické nastavení, které ovlivní způsob zpracování následujících informací, a to i bez vědomého záměru příjemce.

Zajímavý příklad, který demonstruje limitaci a rizika primingu, přináší studie Larana s spol. (2011). Ti zjistili, že zákazníci, kteří byli primováni logem značky Walmart, častěji

inklinovali k levnějším produktům, což odpovídá očekávání založenému na asociaci značky s nízkou cenou. Limit percepce se však ukázal u skupiny, která byla primována přímým sloganem značky („Save Money. Live Better“). Zákazníci z této testovací skupiny paradoxně projevovali vyšší zájem o dražší, prémiové produkty. Tento jev lze vysvětlit tzv. kontrastním efektem, kdy příliš očividná snaha o ovlivnění může vyvolat u příjemce zprávy odpor vedoucí k vynulování efektu, nebo dokonce k efektu opačnému. Tento příklad podtrhuje, že účinnost primingu závisí nejen na samotném obsahu stimulu, ale také na jeho formě a percepci autenticity ze strany recipienta.

1.2.1.2. Retikulární aktivační systém (RAS)

Pro vysvětlení efektu hyper-personalizace je klíčová také funkce lidského mozku nazývaná retikulární aktivační systém (RAS). Tento systém je jeden z důvodů, proč lidé s větší pravděpodobností budou věnovat pozornost sdělení, které je pro ně výslovně adresováno, a to například pomocí jména či jiného konkrétního znaku spojeného s naší osobou (Stevens & Hening, 2007). RAS funguje jako filtr, který automaticky udává váhu jednotlivým datovým vstupům a podvědomě vyhodnocuje, kterým z nich má věnovat pozornost a které jsou nerelevantní či repetitivní. Typickou ilustrací tohoto jevu je efekt koktejlové párty, který byl poprvé popsán v klasické studii Colina Cherryho (1953). Ten zjistil, že i v hlučné místnosti plné překrývajících se hlasů dokáže člověk zachytit své vlastní jméno, přestože ostatní mix slov ignoruje.

I když se efekt koktejlové párty týká sluchových podnětů, myšlenka, která za ním stojí, se odkazuje na schopnost mozku automatické selekce relevantních informací nad informačním šumem. To má pro hyper-personalizovanou reklamu, která s osobními znaky zákazníků pracuje, velký význam. Pokud je správně exekovaná, umožňuje to jejímu sdělení automaticky vystoupit z informační mlhy.

1.2.1.3. Heuristiky a zkreslení

Po zachycení prvotní pozornosti zákazníka se do mixu přidávají tzv. heuristiky, tedy kognitivní zkratky, které lidem pomáhají v rychlém vyhodnocování a rozhodování. Princip heuristik popsali v roce 1974 Tversky a Kahneman. Ti zkoumali časté chyby, kterých se lidé dopouští při úsudcích, a odhalovali psychologické příčiny těchto chyb. I přesto, že ve většině případů tento model usuzování pomáhá lidem dojít rychle ke správným, nebo alespoň k částečně správným závěrům, jeho přesnost při logických úlohách se ukázala jako nízká. Zkreslení, ke kterému u těchto myšlenkových zkratkách dochází, není jen pouhým náhodným šumem kognice, ale jedná se o předvídatelný efekt. V kontextu personalizace jsou důležité dvě konkrétní heuristiky – heuristika dostupnosti a reprezentativnosti.

Heuristika dostupnosti popisuje tendenci lidí přisuzovat větší význam jevům, pro které si jednodušeji vybaví příklady či asociace. V personalizovaném marketingu tak můžeme zvýšit mentální dostupnost informace tím, že připomeneme zákazníkům produkt nebo službu, se kterou se již setkal. Jako klasický příklad lze uvést metody retargetingu, které využívají minulých behaviorálních dat zákazníků a upravují doručovací systém tak, aby zákazníci byli vystaveni zprávě opakovaně. Takto opakovaná expozice zvyšuje mentální dostupnost produktu a může vést k chybnému úsudku, že nabízený produkt musí být plošně populární.

Heuristika reprezentativnosti zase popisuje tendenci lidí hodnotit pravděpodobnost či relevanci jevu na základě podobnosti s existujícím mentálním prototypem. Tversky & Kahneman (1983) tuto heuristiku demonstrovali v klasickém experimentu Linda, ve kterém účastníci dostali následující popis smyšlené osoby: *Lindě je 31 let, je svobodná, upřímná a velmi bystrá. Vystudovala filozofii. Jako studentka se hluboce zajímala o problémy diskriminace a sociální spravedlnosti a také se účastnila protijaderných demonstrací.* Následovně měli za úkol seřadit 8 výroků o Lindě na základě pravděpodobnosti toho, že jsou pravdivé. Tři podstatné výroky byly: (1) *Linda je aktivní ve feministickém hnutí,* (2) *Linda je bankovní úřednice,* (3) *Linda je bankovní úřednice a je aktivní ve feministickém hnutí.* Ukázalo se, že účastníci ve většině případů hodnotí třetí výrok jako nejpravděpodobnější i přesto, že porušuje logické pravidlo konjunkce. Tento jev se v kontextu marketingové personalizace může projevit jako chybné pozitivní vyhodnocení relevance sdělení, které využívá formulace typu „zákazníci jako vy si oblíbili...“. Na základě heuristiky

reprezentativnosti může zákazník přikládat sdělení vyšší relevanci nikoli kvůli objektivní vhodnosti nabízeného produktu či služby, ale kvůli tomu, že obsahuje prvky podobající se jeho mentální představě o sobě samém. Typickým příkladem může být použití vizuálu osoby, která se příjemci podobá věkem či stylem, nebo volba tónu komunikace („tone of voice“), která odpovídají jeho demografickému profilu. Tyto znaky mohou sloužit jako heuristické indikátory, na jejichž základě zákazník intuitivně usoudí, že i samotný produkt či služba jsou pro něj vhodné a to přesto, že k tomuto závěru chybí racionálně podložený základ. Tento mechanismus může vysvětlovat, proč personalizovaná sdělení působí přirozeněji a důvěrněji (Fulton, 2021). Jejich vnímaná relevance může být totiž výsledkem mentální substituce, nikoli analytického vyhodnocení.

1.2.1.4. Elaboration Likelihood Model (ELM)

Kromě výše zmíněných intuitivních zkratk hraje v účinnosti personalizace také Elaboration Likelihood Model (ELM) neboli pravděpodobnostní model elaborace (Petty & Cacioppo, 1986). Tento model se zaměřuje na vliv různých sdělení na formování postojů a následně i chování člověka, a to skrze hloubku, s jakou příjemce obsah sdělení zpracuje. Petty a Cacioppo na základě hloubky procesování definují dvě kvalitativně odlišné cesty persvaze – centrální a periferní. Při centrální cestě příjemce věnuje sdělením vysokou pozornost, do hloubky je zpracovává a hodnotí jejich argumenty. Naopak v případě periferní cesty je přesvědčování povrchnější, jedinec spíše reaguje na jednoduché podněty či emoční apely a nevěnuje detailům takovou pozornost. V tomto případě mohou i relativně jednoduché podněty ve sdělení ovlivnit jeho postoj a chování (Ho & Bodoff, 2014).

Klíčovým faktorem, který rozhoduje, kterou cestou se příjemce vydá, je míra osobní relevance sdělení a jeho motivace a schopnost informace zpracovat. Cílem personalizované komunikace je zpravidla zvyšovat vnímanou relevanci sdělení pro příjemce, čímž podněcuje zpracování sdělení centrální cestou a důkladnější elaboraci obsahu. Je-li nabídka přímo svázána s aktuální potřebou zákazníka, příjemce cítí vysokou osobní zainteresovanost a je ochoten věnovat sdělení více kognitivního úsilí. Výsledek centrálního zpracování bývá vznik pevnějších postojů, které jsou relativně trvalé a odolnější vůči vyvrácení.

Studie potvrzují, že personalizace jako marketingová strategie aktivuje oba typy zpracování dle ELM. Tam & Ho (2005) ukázali, že personalizace může fungovat jako centrální argument, pokud je obsah relevantní a odpovídá individuálním potřebám. Zároveň však může personalizace působit i jako periferní signál, například prostřednictvím oslovení jménem, pochvaly nebo jiného jednoduchého prvku hyper-personalizace, který vyvolává pozitivní emoci u uživatelů s nižší motivací či schopností hlubšího centrálního zpracování. Tento dvojitý účinek personalizace z ní činí flexibilní nástroj přesvědčování, kdy jednak podporuje hloubkové zpracování u zapojených jedinců a u těch méně angažovaných aktivuje intuitivní periferní vyhodnocení.

1.2.1.5. Uses and Gratifications Theory (UGT)

Vztah mezi personalizací a psychologickým účinkem reklamy lze zarámovat také prostřednictvím teorie užití a uspokojení potřeb (Uses and Gratifications Theory, UGT). Ta chápe publikum jako aktivního aktéra, jenž si vybírá média a informace na základě jeho individuálních motivací. UGT předpokládá, že lidé konzumují mediální obsah proto, že jim přináší kognitivní nebo emoční uspokojení (např. získání informací, estetické naplnění, zábavu nebo únik od reality) (Katz et al., 1973). Na tomto teoretickém základu postavil Ducoffe (1996) model vnímané hodnoty reklamy, který rozlišuje kognitivní a afektivní prediktory. Mezi kognitivní aspekty patří především vnímaný informační přínos (informativeness) a důvěryhodnost (credibility), zatímco mezi afektivní faktory spadá vnímaná zábava reklamy (entertainment) a její negativně působící otravnost (irritation).

Personalizovaná reklama může být z pohledu UGT mimořádně účinná právě proto, že cíleně naplňuje uživatelské potřeby, které by buďto jinak zůstaly nenaplněné generickým obsahem, nebo by pro jejich naplnění musel zákazník projevovat proaktivní snahu. Tím, že využívá data o preferencích, zájmech nebo demografii, zvyšuje pravděpodobnost, že dané sdělení bude vnímáno jako relevantní a užitečné (informativeness), čímž se posiluje jeho percipovaná hodnota. Personalizovaný obsah a stylistika sdělení může také lépe rezonovat na emoční úrovni a přinášet tak vyšší míru zábavy (entertainment) a snižovat riziko otravnosti (irritation). Experimentální studie ale zároveň demonstrují rizika invazivně

nastavené personalizace, která může pohledem Ducoffeho modelu (1996) vést k celkovému snížení vnímané hodnoty reklamy.

1.2.2. Psychologické hranice a personalizační paradox

Personalizace je ve své podstatě atraktivní strategií, díky své schopnosti zvýšit relevanci nabídky a naplňovat individuální potřeby zákazníka. Jak ale upozorňuje Rust (2020) tento prodejní argument není zcela bezpodmínečný. Pro dosažení opravdové relevance firemní komunikace je od zákazníka vyžadována pomyslná směna jeho soukromí za personalizaci. Mezi dvěma extrémy – tedy perfektní personalizací a naprostým soukromím – vzniká tak přirozené napětí, které se v odborné literatuře označuje jako personalizační paradox.

Personalizační paradox popisuje mentální rozkol zákazníků mezi vnímanou relevancí sdělení a kontrolou nad svým soukromím. Větší personalizace obvykle zvyšuje relevanci služeb a jejich osvojení zákazníky, ale paradoxně může také zvýšit pocit zranitelnosti zákazníků a snížit míru přijetí. Navzdory studiím demonstrujícím zvyšující se míru odezvy s větší mírou personalizace, výzkumy v oblasti datového soukromí ukazují, že tento vztah není lineární. Příliš vysoká míra personalizace může být vnímána jako invazivní a způsobit opačný efekt jak na vnímání reklamy, tak na její samotnou efektivitu (Aguirre et al., 2015; Němeček, 2022).

1.2.2.1. Hranice relevance a invazivitou

Hranice mezi relevancí a invazivitou personalizace se ukazuje jako velmi dynamická a záviselá na kontextu. Někteří akademici se pro její vytyčení obracejí k racionalistickému přístupu k rozhodování, který je popsán Beckerem (1976) jako vnímání spotřebitele jako aktéra, který vědomě zvažuje přínosy a rizika jeho rozhodnutí. Autoři tento pohled na logiku úsudku využili pro kvantifikaci vztahu mezi relevancí a invazivitou personalizace (Hann et

al., 2007; Xu et al., 2011). Vzniklý koncept *rovnice soukromí* (privacy calculus) vyjadřuje ochotu zákazníka sdílet osobní údaje funkcí poměru mezi vnímaným užitekem (např. lepší služby, úspora času) a rizikem (např. zneužití dat, manipulace rozhodnutí). Výzkumy ukazují, že pokud vnímané benefity personalizace přesahují vnímaná rizika, spotřebitelé mají menší obavy o soukromí a jsou ochotnější poskytovat své osobní údaje (Zhu & Chang, 2016).

Zhu a Chang (2016) také vyzdvihují vliv relevance na výsledky rovnice soukromí. Podle jejich výzkumu právě míra relevance doručeného sdělení působí jako tlumící faktor obav zákazníků o jejich datové soukromí. Pokud je sdělení vnímáno jako užitečné nebo příjemné, ztráta části soukromí je vnímána jako přijatelná

Alternativní pohled na vnímání relevance a invazivity personalizace nabízí tzv. *privacy paradox*, který upozorňuje na rozkol mezi tím, co zákazníci deklarují o svém postoji vůči ochraně soukromí, a tím, jak se ve skutečnosti chovají. Přestože lidé často vyjadřují silné obavy o své soukromí, jejich reálné chování, například ochota sdílet osobní údaje výměnou za minimální odměnu, bývá v přímém rozporu s těmito postoji. Studie Carrascal a spol. (2013) ukázala, že uživatelé byli ochotni poskytnout historii svého prohlížeče za částku odpovídající ceně BigMac menu ve fastfoodu. Zajímavým případem *privacy paradoxu* je studie monitorující chování nizozemských uživatelů na internetu po uvedení zákona o souborech cookies z roku 2013 (Aguirre et al., 2015). Prvotní data potvrzovaly očekávaný propad v efektivitě personalizované reklamy. Tento trend se ale po devíti týdnech otočil a efektivita začala stoupat nad hranice před uvedením zákona do platnosti. Tento paradox lze vysvětlit řadou psychologických a behaviorálních faktorů, včetně okamžitého uspokojení, omezené racionality, optimistického zkreslení nebo vlivu afektu na rozhodování (Acquisti, 2004; Acquisti & Grossklags, 2005).

I přes tato legislativní opatření podle výzkumu většina lidí při registraci na sociální síť ignoruje zásady ochrany osobních údajů (Obar & Oeldorf-Hirsch, 2020). Zajímavý vhled do této problematiky přinesla také studie z Nizozemska, která v při zavedení zákona o souborech cookies měřila jeho dopad efektivitu personalizované reklamy. Podle výsledků mělo zavedení negativní vliv na efektivitu reklamy prvních devět týdnů. Po uplynutí tohoto

času začala efektivita znovu stoupat a překročila dokonce původní hranici před zavedení tohoto zákona. Autoři tento efekt vysvětlují tím, že lidé si na sběr dat zvykli a začali zřejmě oceňovat i transparentnost sběru dat (Aguirre et al., 2015).

1.2.2.2. Kontextuální rozdíly ve vnímání personalizace

Důležitým aspektem je také kontext, ve kterém je personalizační sdělení zákazníkem přijato. Například výzkum Hess et al. (2020) ukázal, jak jinak reagujeme na sdělení v soukromí a jinak na veřejnosti. Personalizovaná sdělení promítaná na veřejnosti (např. v retailových prostorech) mohou dle výsledků výzkumu v určitých případech vyvolávat stud nebo trapnost. Tento efekt je zejména viditelný, pokud se týkají reklam ohrožující sebepojetí zákazníka a je zprostředkován vnímaným sociálním tlakem a přítomností ostatních. Naopak lichotivá personalizace může ve veřejném prostoru působit pozitivně, pokud nepřekračuje hranici vhodnosti.

Stejně tak se ukazuje, že personalizace je v některých prostředích lépe akceptována. Například větší toleranci vykazali ve studii srovnávající on-line prostředí oproti off-line zákazníci e-shopu (Wetzlinger et al., 2017). Dále byl také zjištěn vliv typu a povahy produktů. Studie z dílny Priyadharshini & Mathew (2016) ukazuje, že personalizované reklamy na choulostivé produkty (konkrétně spodní prádlo nebo přípravky na vypadávání vlasů) mohou v porovnání s klasickými produkty vyvolat negativní reakci, což se projevuje poklesem interakcí i konverzního poměru.

1.3. AI, strojové učení, GenAI a jejich využití v personalizaci

1.3.1. Definice pojmů umělé inteligence

Tato kapitola se zaměřuje na definice a základní funkční principy technologií spojených a podružených pod pojmem umělé inteligence. Zároveň si ukládá za cíl rozřazení těchto technologií do hierarchické struktury, která může vnést světlo na vztah mezi nimi. Pojmy jako AI, GenAI, strojové učení a LLM, jsou totiž často používány zaměnitelně, a to nejen v médiích a populárně naučných publikacích.

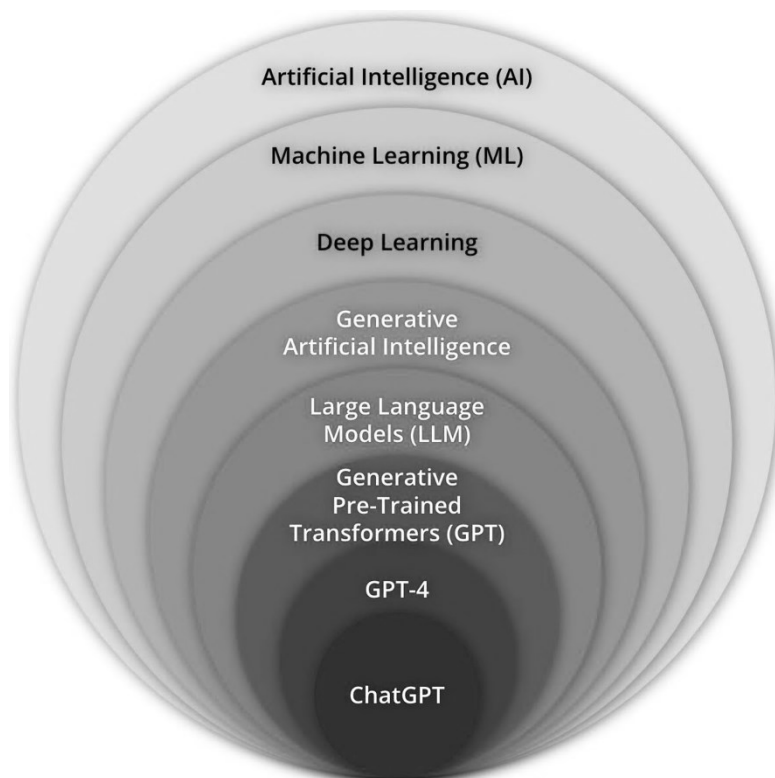


Schéma 3 – Hierarchie pojmů umělé inteligence (Vasile, 2024)

Tato kapitola se bude držet technické typologie umělé inteligence a půjde po jednotlivých vrstvách od obecných zastřešujících pojmů až po konkrétní technologie (viz. Schéma 3). Na pomyslné nejvyšší úrovni stojí všeobjímající pojem *umělá inteligence* (Artificial Intelligence, AI), který se dále rozpadá na podmnožiny podle jejich funkce. Jednou z těchto podmnožin je *strojové učení* (Machine Learning, ML), které představuje systémy schopné

sebezdokonalování a optimalizace z dat. Specifickou podmnožinou strojového učení je pak *hluboké učení* (Deep Learning, DL), využívající hluboké *neuronové sítě* (Neural Networks). Dále práce zmíní specializované subdomény umělé inteligence, zaměřené na konkrétní typy dat, jako například *počítačové vidění* (Computer Vision) pro zpracování obrazových informací a *zpracování přirozeného jazyka* (Natural Language Processing, NLP) pro práci s lidským jazykem. V posledních letech získaly na významu *velké jazykové modely* (Large Language Models, LLM), které spadají do oblasti NLP a hlubokého učení a představují funkční jádro současného trendu *generativní AI* (Generative AI, GenAI), tedy multimodální modely umělé inteligence schopné generovat multimediální obsah. Následující podkapitoly popisují jednotlivé úrovně této hierarchie ve větším detailu, včetně definic pojmů, principů fungování a příkladů jejich využití.

1.3.1.1. Umělá inteligence (Artificial Intelligence)

Termín *umělá inteligence* (Artificial Intelligence, AI) byl poprvé použit matematikem Johnem McCarthym, který ho definoval jako vědu a inženýrství za tvorbou inteligentních strojů, zvláště inteligentních počítačových programů (*What is AI? / Basic Questions*, 2011). Stalo se tak v rámci Dartmouthské konference v roce 1956, která se považuje za formální počátek oboru umělé inteligence. Cílem této výzkumné konference skládající se z matematiků, informatiků, lingvistů, psychologů a neurologů, bylo zjistit, jak propojit počítače s přirozeným lidským jazykem, a jak pomocí nich řešit abstraktní koncepty a problémy na lidské úrovni (McCarthy et al., 1955).

I přesto, že konference jako taková nepřinesla výrazné průlomy v těchto otázkách, panoval v prvních dekádách výzkumu umělé inteligence optimismus ohledně rychlého pokroku v jak v teoretickém pojetí, tak v prvních aplikacích umělé inteligence. Výzkumníci nicméně brzy narazili na omezení v možnostech výpočetní techniky a také na zvýšenou komplexitu problémů. To vedlo v až k období zpomalení vývoje a investic do umělé inteligence známém jako AI zima (Russell & Norvig, 2021). Toto ochlazení přimělo vědeckou komunitu změnit přístup od původní vize všeobecné umělé inteligence k více pragmatickému pohledu zaměřenému na specifické aplikace známé také jako expertní systémy. Ty se od

ambiciózního cíle replikace obecné lidské inteligence odklonily k řešení konkrétních, úzce vymezených problémů.

Tato změna se přirozeně odrazila i na evoluci definic umělé inteligence. Definice se postupně posouvají od abstraktních formulací zaměřených na inteligenci a racionalitu směrem ke konkrétnějším popisům zaměřujícím se na specifické rysy a praktické schopnosti systémů. I přesto není definice tohoto pojmu v akademických kruzích ustálena a stejně jako chápání umělé inteligence se i její definice neustále formuje.

Stejně jako ve své bakalářské práci na téma *Umělá inteligence jako nástroj pro personalizaci reklamy* jsem jako výchozí zvolil definici od Michala Pěchoučka, ředitele AI centra při Fakultě elektrotechnické na ČVUT v Praze. Ten umělou inteligenci chápe jako soubor technologií a vědní obor, zkoumající a umožňující automatizaci, zrychlování a extrémní škálovatelnost lidského vnímání, uvažování a inteligentního rozhodování (Neurazitelný.cz, 2019). Pro aktualizaci této pět let staré definice je nutné ke třem zmíněným lidským kognitivním schopnostem doplnit i poměrně nově nabytou schopnost tvořit, kterou umožnil skokový vývoj ve velkých jazykových modelech (viz. kapitola Velké jazykové modely). Na rozdíl od jiných tato definice vnímá možnost překonání efektivity lidských kognitivních schopností v různých oblastech.

S vlastní definicí přišel i Evropský parlament skrze Akt o umělé inteligenci (AI Act), který jako první nařízení na světě reguluje použití systémů umělé inteligence. Dle Evropského parlamentu (2024) je umělá inteligence „strojový systém navržený tak, aby po zavedení fungoval s různými úrovněmi autonomie a který po zavedení může vykazovat adaptabilitu a který za explicitními nebo implicitními účely z obdržených vstupů odvozuje, jak generovat výstupy, jako jsou predikce, obsah, doporučení nebo rozhodnutí, které mohou ovlivnit fyzická nebo virtuální prostředí.“.

Russell a Norvig (2021) vidí jako průsečík definic právě cíl vývoje AI, tedy vyvinout systémy schopné samostatně řešit problémy, rozhodovat se a vykazovat inteligentní či racionální chování v různých situacích podobně jako člověk.

Z praktického pohledu jde o to, aby stroje dokázaly vnímat své okolí, učit se, uvažovat, plánovat a jednat tak, aby dosahovaly zadaných cílů.

1.3.1.2. Strojové učení (Machine Learning)

Strojové učení (Machine Learning, ML) je podoblastí AI, která se zabývá systémy se schopností autonomního učení. Russell a Norvig (2021) ho definují jako agenta, který dokáže systematicky optimalizovat a zdokonalovat své chování prostřednictvím analýzy dat. Klíčovou funkcí těchto systémů je tvorba a trénování modelů, na jejichž základě pak agent formuluje hypotézy a řeší problémy. Hlavní výhodou těchto systémů je schopnost kontinuálního učení a zlepšování se bez nezbytnosti explicitního programování každého kroku, stejně jako možnost přenášet naučená pravidla a aplikovat je na nové datové vstupy. Právě podle způsobu, jakým se strojové učení z dat učí, ho můžeme rozdělit do třech základních kategorií.

Učení s učitelem (supervised learning) je základní metodou strojového učení, při které agent ve fázi tréninku dostává předem připravené dvojice datových vstupů a optimálních výstupů (tzv. labelů). Cílem agenta je pak nalézt aproximační funkci, která dokáže vztah mezi vstupy a výstupy co nejlépe napodobit a následně jej generalizovat na data dosud nová. Takto spárované datové body mohou mít podobu tříd, jedná-li se o klasifikaci, nebo hodnot jedná-li se o regresi (Russell & Norvig, 2021). V případě klasifikace by se v praxi mohlo jednat například o rozpoznávání člověka na obrázku, kdy by tréninkovým data setem bylo velké množství obrazových vstupů s binárním výstupem podle přítomnosti člověka (tzn. 0 = nepřítomnost člověka, 1 = přítomnost člověka). Na základě trénovacích dat si agent vytvoří predikční model, který při vložení nového obrázku určí přítomnost člověka i přesto, že tomuto konkrétnímu obrazovému vstupu nebyl nikdy vystaven. Při regresi se může například jednat o model predikující tržní cenu nemovitosti. Tréninková data by v tomto případě obsahovala spojitě vstupní proměnné (např. rozloha pozemku, počet pokojů, stáří budovy, vzdálenost od centra) a odpovídající číselné výstupy představující reálné ceny nemovitostí. Model by se v tomto případě učil mapovat vztahy mezi vstupy a výstupy, aby dokázal odhadnout cenu nové nemovitosti na základě jejích atributů. K vyhodnocení efektivity

modelu využíváme rozdělení testovacího data setu na trénovací, testovací množinu (Russell & Norvig, 2021). Ve fázi trénování modelu dáváme přístup jen k trénovací množině, která obvykle představuje 80 % data setu. Ve fázi testování výkonnosti modelu pak využijeme zbylých 20 % dat a porovnááme odchylku oproti dopředu labelovanými daty.

Učení bez učitele (unsupervised learning) na rozdíl od předešlé metody hledá strukturu v datech bez předešlého označení, trénování či zpětné vazby. Nejčastější využití mají tyto modely v takzvaném shlukování (clustering), při kterém agenti hledají vzory v poskytnutých vstupních datech a jako výstup poskytnou shluky dat s určitou podobností. Typickým příkladem by byl model, který by po analýze miliónů obrázků na internetu dokázal sám od sebe dokázat určit shluk obrázků, na kterých se vyskytla kočka. Model přitom nemá žádný kontext, co to kočka znamená, nebo že se vůbec shluk nazývá kočkou, pouze dává dohromady datové podobnosti. Výhodou této metody je možnost využití neklasifikovaných dat, která jsou obecně dostupnější než anotované datové sety potřebné pro učení s učitelem. Tento přístup je však limitován nutností velkého množství dat, neboť bez poskytnutých labelů je pro model náročnější odhalit v datech relevantní struktury. Přesto se tato metoda strojového učení ukázala jako efektivní například v zachytávání anomálií ve výrobním procesu automobilek (Zhang et al., 2024), či ve studiu urbanizace a městském plánování (Wang & Biljecki, 2022).

Zpětnovazebné učení (reinforcement learning) funguje na metodě zpětných vazeb ve formě odměn a trestů, přičemž cílem agenta je maximalizovat jeho kumulativní odměnu (Sutton & Barto, 2018). Ve srovnání s ostatními metodami se tato liší v její proaktivní povaze, kdy se model může vylepšovat autonomně skrze pokus-omyl. Typickým příkladem využití této metody je model AlphaGo, který v roce 2016 porazil světového mistra v Go, strategické deskové hře, která je považována za jednu z nejsložitějších na světě. Základ modelu AlphaGo od společnosti DeepMind byl trénován metodou učení s učitelem, ale hlavní průlom přišel při zapojení zpětnovazebného učení, při kterém model simuloval tisíce partií proti svým různým verzím a podle výsledku hry dostával odměny nebo tresty (Silver et al., 2016). Je pak čistě na agentovi, aby analyzoval vztahy mezi výsledky a jeho chováním, a adaptivně měnil své budoucí strategie pro maximalizaci dlouhodobé výkonnosti.

1.3.1.3. Hluboké učení (Deep Learning)

Hluboké učení (Deep Learning) je v momentální době nejviditelnější a nejzkoumanější podkategorie strojového učení. Ačkoli jeho teoretické základy byly položeny McCullochem a Pittsem (1943) už ve 40. letech minulého století, pravý potenciál této inovace přišel až s nárustem výpočetního výkonu počítačů – konkrétně grafických procesorů (graphics processing unit, GPU). Právě progres v počítačovém hardwaru považuje vedoucí AI výzkumník v Meta a průkopník hlubokého učení Yann LeCun jako nejzásadnější překážku pro budoucí vývoj v hlubokém učení (AI at Meta, 2020).

Hluboké učení je založeno na *umělých neuronových sítích* (Artificial Neural Networks, ANN), které svou strukturou do jisté míry připomínají síť neuronů v lidském mozku. Tyto sítě fungují na bázi vícevrstvých výpočetních uzlů, které umožňují zpracovat vstupní data nelineárně. Každý z těchto propojených uzlů se časem učí a ukládá paměť. Paměť uzlů může být buď fixní, kdy důležitost každého konkrétního uzlu zůstává konstantní, nebo adaptivní, kdy se důležitost konkrétního uzlu se může v čase měnit (LeCun et al., 2015). Propojení mezi těmito uzly se nazývá parametry a využívají se jako hlavní měrnou jednotkou velikosti neuronových sítí.




Schéma 4 – Schéma umělé neuronové sítě (Nielsen, 2015)

V případě hlubokého učení je neuronová síť složena z velkého množství uzlů a vrstev, což umožňuje modelům vyhodnocovat data v různých úrovních abstrakce. Právě abstrakce umožňuje modelům rozpad komplexních problémů reálného světa – jako například

rozeznání obrázku kočky – na postupné kroky. Zatímco první vrstvy mohou být zaměřené jen na kontrasty a hrany v obraze, poslední vrstvy už dokáží detekovat specifické aspekty jako tvar kočičích uší. Oproti klasickým algoritmům strojového učení mají hluboké sítě výhodu ve své univerzálnosti a schopnosti pracovat s nestrukturovanými daty jako obraz nebo text. Tato výhoda je však vykoupena vysokými nároky na velikost trénovacích dat, výpočetní kapacitu a obecně nižší schopností interpretace modelu.

Díky hlubokému učení došlo i k pokrokům v oblastech medicínské diagnostiky (např. český startup Carebot), bioinformatice (např. projekt AlphaFold od firmy DeepMind), ale jsou také jádrem technologie generativní umělé inteligence (např. ChatGPT, Claude, DeepSeek apd.) Hluboké učení se tak stalo jedním z nejviditelnějších a nejúspěšnějších směrů AI v současnosti.

1.3.1.4. Počítačové vidění (Computer Vision)

Počítačové vidění (Computer Vision) je multidisciplinární obor AI, zabírající se schopností strojů analyzovat a porozumět vizuálním datům jako například fotografiím či videím. Podle Russella a Norviga (2021) obor počítačového vidění řeší dva základní problémy – rekonstrukce a rozpoznávání. Rekonstrukce je dle autorů schopnost agenta vytvářet model světa na základě vloženého obrazu nebo jeho souborů. Rozpoznávání na druhou stranu označuje funkci rozlišit objekty, se kterými se agent setká, převážně na základě jejich vizuálních informací.

Pandey (2023) mezi základní úlohy počítačového vidění řadí například *klasifikaci obrazu*, kdy algoritmus kategorizuje vizuální vstupní data do předem určených tříd podle toho, co se na daném obrázku vyskytuje; *detekci objektů*, která na obrázku či ve videu lokalizuje více objektů a označí jejich hrubou polohu na snímku obvykle pomocí obdélníku; *segmentaci obrazu a instancí*, jež rozdělí obraz na podoblasti odpovídající jednotlivým objektům nebo povrchům; *sledování objektů* a jejich pohybu napříč na sebe navazujícími snímky ve videosekvencích; *odhadování pózy*, která se zabývá určováním orientace objektů či lidí v prostoru.

V minulosti se počítačové vidění praktikovalo na relativně úzce definované problémy v předem určeném prostředí. Modely často vyžadovaly specifické datové sety postavené na míru konkrétním případům a jejich schopnost generalizace pro komplexnější a méně kontrolované scénáře byla omezená. V posledních letech však došlo k zásadnímu posunu díky integraci počítačového vidění a velkých jazykových modelů. Prvním modelem tohoto druhu byl CLIP od firmy OpenAI (Radford et al., 2021). Ten prokázal, že trénink na velkém množství nestrukturovaných dat obsahujících jak text, tak obraz umožňuje modelům chápat vizuální informace na mnohem abstraktnější úrovni a aplikovat je v různorodých úlohách. Tomuto konceptu se říká *zero-shot learning* (jednorázové učení), tedy možnost aplikovat model umělé inteligence bez potřeby specifického tréninku na danou úlohu (Xian et al., 2018). Tento přístup odemyká nové možnosti v odvětvích odkázaných na hlubší kontext a adaptabilitu modelů, jako zákaznická analýza, obsahová moderace, behaviorální predikce či dynamická personalizace reklam.

1.3.1.5. Zpracování přirozeného jazyka (NLP)

Zpracování přirozeného jazyka (Natural Language Processing, NLP) je obor zabývající se interakci mezi počítači a lidským jazykem. Tento obor zahrnuje poznatky z různých oborů, včetně lingvistiky, statistiky a strojového učení (Mishra & Kumar, 2020). Právě propojení strojů a jazyka bylo ve středobodu umělé inteligence od jejího úplného počátku. Již v dokumentu svolávající Dartmouthskou konferenci, na které byl poprvé použit termín umělá inteligence, McCarthy a spol. (1955) poznamenali jako stěžejní aspekt zkoumání „How Can a Computer be Programmed to Use a Language“, tedy jak může být počítač naprogramován k použití přirozeného jazyka. Autoři zároveň v dokumentu vznesli úvahu, že formování zobecnění znamená zavedení nového slova a pravidel pro jeho logické odvození. Tato myšlenka by se dala chápat jako ranná intuice pro základní principy, na kterých funguje dnešní technologie NLP – tedy že význam slov je v ANN matematicky zakódován jako vztah k ostatním slovům.

Cílem moderního NLP je umožnit počítačům porozumění, interpretaci a vytváření jazyka skrze text, či mluvené slovo. To pro algoritmy znamená nutnost zvládnout komplexitu slovní zásoby, gramatických pravidel, kontextuálních rozdílů a záměrů za sdělením. Takto natrénované modely pak mohou řešit konkrétní úlohy například *analýzu sentimentu* tedy určení emočního zabarvení textu; *strojový překlad* umožňující automatický překlad mezi dvěma jazyky; *extrakce informací* tedy získávání strukturovaných informací z nestrukturovaného textu; *generování textu* neboli automatická tvorba vlastního textu na základě zadání či jiných vstupních dat; *odpovídání na otázky* v přirozeném jazyce s možnou referencí na databázi znalostí nebo *sumarizace textu* tedy zkrácení dlouhého obsahu do krátkého vystihujícího shrnutí (Patwardhan et al., 2023).

K řešení těchto úloh se v historii NLP vystřídaly různé přístupy. Původní systémy v 60. a 70. letech 20. století často využívaly ručně zakódovaná pravidla pro analýzu a překlad vět. Ty se skládaly z gramatických pravidel a slovníkových dvojic na základě kterých se výzkumníci snažili demonstrovat například schopnost překladu textu. Tyto systémy ale nezapočítaly obrovskou komplexitu a množství výjimek, které v sobě má jazyk skryté. S tím pomohly 90. léta a příchod statistických modelů společně s digitálními texty. Zásadní průlom ale nastal se zapojením hlubokého učení do zpracování přirozeného jazyka a příchodem transformer architektury.

Transformer architektura byla poprvé navržena v roce 2017 nyní již v kultovním článku *Attention Is All You Need* výzkumníky z Google (Vaswani et al., 2017). Ta už podle názvu pracuje s mechanismem pozornosti, který modelu umožňuje paralelně zpracovávat celé sekvence slov a zároveň zachytit závislosti mezi slovy bez ohledu na jejich vzdálenost v textu. K tomu jsou využívány takzvaná tokenizace, tedy rozdělení vstupních dat na jednotlivá slova, nebo jejich části. Každý token je následovně převeden na vektorovou reprezentaci, která v sobě uchovává význam tokenu ve vztahu s ostatními slovy. Pro významově podobná slova jako *kočka* a *pes* by si vektory byly bližší než například pro slovo *tramvaj*. Tato architektura umožnila efektivně trénovat obrovských textových datech a je základem většiny dnešních velkých jazykových modelů (viz. písmeno T v akronymu GPT – Generative Pre-trained Transformer).

1.3.1.6. Velké jazykové modely (LLM) a generativní AI

Velké jazykové modely (Large Language Models, LLM) jsou poslední nejgranulárnější podkategorií v dělení této práce vycházející z technologie popsané v předešlých podkapitolách. Přívlastek velké odkazuje na obrovský objem parametrů, ze kterých se tyto modely díky tréninku na masivních textových, ale i vizuálních datových sítích skládají. Například velikost velkého jazykového modelu ChatGPT 4 se odhaduje na 1,76 biliónu parametrů (Schreiner, 2023). Právě zdánlivě neomezená škálovatelnost těchto modelů je důvod jejich rychlé evoluce a globální adopce.

Myšlenka je taková, že škálováním velikosti modelu i objemu trénovacích dat lze dosáhnout nových schopností modelu. Skutečně, výzkum ukázal, že zvětšováním objemu trénovacích dat a parametrů se model nejen zlepšuje v běžných metrikách jako rychlost, ale začne vykazovat emergentní schopnosti, které menší modely nemají (Zhao et al., 2023). Mezi takové schopnosti patří například lepší porozumění kontextu, schopnost řešit nové úlohy bez explicitního tréninku na nich (zero-shot learning) či generování koherentnějších výstupů.

LLM typicky využívají výše popsanou transformer architekturu a jsou vytrénovány pro úlohu predikce nejhodnějšího následujícího slova. Skrze tréninku na velkých datových sítích volně přístupného webového obsahu, knih a článků získává model obecné znalosti o jazyce a světě, které jsou zachyceny ve vahách neuronové sítě (Brown et al., 2020). Tento takzvaný *základní model* (foundation model) se pro praktické využití následovně *doladuje* (fine-tuning) metodou učení s učitelem, aby byl schopen plnit specifické úlohy jako například odpovídání na otázky. Model pracuje s menším vzorkem předem spárovaných dvojic od lidských testerů, které představují optimální vstup a výstup (např. otázku a odpověď) a úkol základního modelu je naučit se tento styl výstupů mimikovat (Heaven, 2025). OpenAI tento proces trénování inovovalo zapojením třetího kroku, který využívá *zpětnovazebné učení s lidským hodnocením* (Reinforcement Learning with Human

Feedback, RLHF). Při RLHF se doladěný model dále optimalizuje podle hodnocení jeho výstupů lidskými testery. Cílem modelu se tak jako u klasického zpětnovazebného učení stane maximalizování kumulativní odměny, čímž se přizpůsobuje lidským preferencím (Ouyang et al., 2022). Vedle tohoto paradigmatu v tréninku LLM, který využívají největší hráči jako OpenAI, Microsoft, Anthropic či X, se objevují i alternativní přístupy. Například čínský projekt DeepSeek do jisté míry automatizoval proces doladování modelu a minimalizoval tak potřebu rozsáhlého týmu lidských testerů. To je z pohledu času a nákladů na vývoj a trénink modelů zásadní posun (Heaven, 2025).

Velké jazykové modely dnes představují jádro *generativní umělé inteligence* (GenAI). Generativní AI označuje systémy umělé inteligence, které jsou schopny obsah nejen analyzovat, ale také generovat. Nemusí se přitom jednat o jen o textová data, ale díky propojení LLM a počítačového vidění metodami typu CLIP (viz. podkapitola Počítačové vidění), vznikají modely s různou modalitou. Ty dokáží generovat obrázky (např. DALL-E, Midjourney či Stable Diffusion), videa (Sora, Runway nebo Wan) nebo hlas (např. ElevenLabs nebo Speechify). Rozvoj generativní AI výrazně akceleroval kolem roku 2022, a to právě díky pokroku v hlubokých neuronových sítích a dostupnosti velkých modelů. Zároveň se v této době etabloval nový standard pro interakci s modely takzvané promptování. Prompt je strukturované zadání, typicky ve formě textových dat, kterým uživatel specifikuje požadovaný výstup modelu. Efektivní formulace promptu se stala klíčovou dovedností pro dosažení kvalitního a relevantního generovaného obsahu

1.4. Data – význam, typologie a zdroje

Nyní už notoricky známá fráze „*data is the new oil*“ (česky „data jsou novou ropou“), se kterou v roce 2006 přišel Britský matematik Clive Humby, byla na svou dobu vizionářská (Arthur, 2013). Za dobu od jejího prvního vyřčení si typ dat, způsob sběru a analýzy prošly výraznou proměnou. Humby jako zakladatel věrnostních programů Tesco Clubcard s frází přišel v době prvních webových banerů a fyzických věrnostních programů – dávno před nástupem sociálních sítí, omnichannel remarketingu či pokročilých algoritmů.

Po téměř 20 letech význam této fráze opět nabírá nové výše. S celosvětovou vlnou velkých jazykových modelů, jejichž funkce do značné míry závisí na kvantitě trénovacích dat, se začaly vycházet na povrch otázky ohledně jejich původu a budoucnosti trénování. Například odhadovaná velikost data setu využitého k tréninku modelu GPT-4 z roku 2023 se podle zdrojů pohyboval kolem 1 petabytu (E2Analyst, 2023). To pro lepší představu odpovídá ekvivalentu textového dokumentu o 678 000 000 000 stranách.

Právě tato potřeba velkých dat pro trénink nových jazykových modelů je obvykle naplněna automatizovaným procházením volného internetu a sběrem knih, článků, kódu, příspěvků na sociálních sítích či formátů jako obrázků nebo videí. Právě plošná podstata tohoto sběru dat pak může vést ke shromažďování obsahu, který je pod ochranou autorských práv (Dang, 2024). Například vydavatelé jako The New York Times podali žaloby na OpenAI a Microsoft za porušování copyrightu při použití jejich obsahu pro trénink modelu ChatGPT (AP News, 2025). Výrazný posun v přístupu ukazuje případ komunitní sociální sítě Reddit, která se společností Google uzavřela dohodu na zpoplatněné právo používat jejich obsah k tréninku jazykových modelů. Podle agentury Reuters se výše kontraktu odhaduje na 60 milionů dolarů ročně (Tong et al., 2024). Tyto případy naznačují zásadní změnu v tom, jak veřejnost a firmy začínají nahlížet na hodnotu a vlastnictví dat, která byla dříve vnímána jako volně dostupná a bez jasné právní ochrany.

Vedle právních aspektů vyvstává další, čistě praktický problém. Objem lidsky generovaných veřejných textových dat je konečný a blížíme se k dosažení jeho limitů. Analýza výzkumné skupiny Epoch AI (Villalobos et al., 2022) odhaduje, že při současné míře trénování mohou být veškerá veřejná a efektivně použitelná textová data spotřebována už mezi lety 2025 a

2028. Firmy trénující tyto modely tento problém snaží řešit pomocí takzvaných syntetických data setů, tedy dat, které mohou být například upravenou verzí existujících dat či kompletně uměle vytvořeny. Z pohledu výzkumu a komerčních aplikací AI to znamená, že přístup ke kvalitním, legálně využitelným a eticky spravovaným datům se stává klíčovým strategickým aktivem.

1.4.1. Typologie dat podle segmentační logiky

Pro systematické uchopení personalizačních dat byla zvolena typologie segmentačních celků. Farruh (2020) ve své studii uvádí devět základních segmentů z pohledu data miningu, které pro účely této práce byly doplněny a jejich užití je ukázáno na řadě personalizačních experimentů.

1.4.1.1. Geografická segmentace

Geografická data jsou základem segmentační logiky. Ta je založena na premise, že preference, potřeby a normy se mohou významně lišit v závislosti na geografickém umístění zákazníka. Praktické využití geografické personalizace se dnes uplatňuje především prostřednictvím technologií, které na základě IP adresy nebo GPS signálu přizpůsobují obsah pro jednotlivé geografické segmenty. Typickým příkladem je automatické přepnutí jazykové mutace webové stránky podle detekované země uživatele, nebo zobrazení lokálně dostupných produktů.

Na geografickou segmentaci se zaměřil výzkum Kliman-Silver a spol. (2015), který prokázal významnou roli lokality uživatele na výsledky webového vyhledávání. Autoři demonstrovali, že ke geografické personalizaci nedochází jen na mezinárodním měřítku, ale i v rámci jedné země. Nejvýraznější změna mezi výsledky byla zachycena v rámci takzvaných lokálních dotazů na podniky či služby. Geolokace nefunguje pouze jako nástroj

technického přizpůsobení, ale může sloužit i jako proxy pro další demografické charakteristiky (např. příjem, vzdělání nebo politická orientace), čímž se stává významným faktorem v přesné cílené komunikaci.

1.4.1.2. Demografická segmentace

Demografická data jsou data zahrnující základní proměnné o zákaznících jako je věk, pohlaví, zaměstnání, příjem, nebo rodinný stav. Demografie se považuje za tradiční segmentační metodu marketingu díky své schopnosti relativně snadno rozdělit širokou populaci do menších skupin jako generací či socio-ekonomických tříd. V kontextu personalizace demografické údaje často slouží jako výchozí vrstva cílení: například jinou formu sdělení volíme pro mladší publikum a jinou pro seniory, nebo odlišné produkty doporučíme mužům a ženám na základě obecně odlišných preferencí daných demograficky. I přes svou snadnou aplikovatelnost mají demografická data však samy o sobě jen omezenou výpovědní hodnotu, protože nebere v potaz rozdíly v motivacích a potřebách jedinců ve stejných věkových nebo socio-ekonomických segmentech.

V době algoritmičké personalizace byla demografická data nahrazena behaviorální segmentací, která umožňuje lépe vyhodnocovat chování lidí při nákupu. S nástupem nové éry personalizace, která umožňuje využití tohoto druhu dat k vytváření kontextuálně relevantních argumentů přímo pro jedince na masové úrovni, se demografická data mohou vracet do hledáčku komunikačních expertů. Například v experimentu zkoumajícím přesvědčivost LLM modelů Salvi a spol. (2024) shromáždili demografická data, jako je pohlaví, věk, etnicita, úroveň vzdělání, zaměstnanecký status a politická příslušnost, aby přizpůsobili argumenty pro debaty. Výsledek experimentu ukázal 61.4% nárůst ve přesvědčivosti při porovnávání LLM modelu s přístupem k demografickým datům vs bez přístupu k nim.

1.4.1.3. Behaviorální segmentace

Behaviorální segmentace vychází z dat o chování spotřebitele včetně historii nákupů, prohlížených produktů, četnost a délku návštěv webových stránek, interakce s aplikací, reakce na kampaně (otevření emailu, klik na reklamu), způsob používání produktu, ale i metriky jako čas strávený u určitého obsahu či cesta uživatele webem. Tento typ dat je cenný pro predikci reakcí zákazníků na budoucí marketingové aktivity obzvláště proto, že zachycují skutečné chování, které je spolehlivějším ukazatelem ve srovnání s meta-hodnotícími metrikami, které jsou založeny na úsudcích o vlastnostech zákazníků (Kaptein, 2018). V personalizaci jsou behaviorální data klíčová zejména pro doporučovací systémy a prediktivní modely ve kterých algoritmy strojového učení analyzují data o chování cílového zákazníka a porovnávají je se vzorci chování zbytku uživatelů. Právě tato agregace dat jim umožňuje predikovat preference jednotlivce a nabídnout mu obsah, se kterým s velkou pravděpodobností bude interagovat. Příkladem je doporučování filmů na základě toho, jaké filmy uživatel dokoukal, nebo personalizace e-shopu podle minulých nákupů a prohlížených položek.

1.4.1.4. Psychografická segmentace

Psychografická data jdou nad rámec klasické deskripce zákazníka a zaměřují se na hlubší motivace pro jeho chování. Jedná se o psychologické charakteristiky uživatele, jako jsou jeho osobnost, hodnoty, postoje, hodnoty či životní styl (Sandy et al., 2013). Psychografická segmentace tedy namísto vnějších znaků zohledňuje vnitřní povahové rysy a motivace lidí, a poskytuje vhled do emočních rysů spotřebitele. Typickým příkladem psychografických dat jsou osobnostní rysy podle pětifaktorového modelu osobnosti (Big Five). Ten zjednodušeně popisuje lidskou osobnost na základě pěti faktorů: *extraverze* (extraversion), neboli míra, do jaké jsou lidé společenší a komunikativní, *přívětivost* (agreeableness) označující míru kooperace a soucitu s ostatními, *svědomitost* (conscientiousness) charakterizovaná sebekázní, vysokou efektivitou a cílevědomostí, *neuroticismus* (neuroticism) míra, do jaké jsou lidé náchylní k prožívání negativních emocí a *otevřenost* (openness) či sklon k radosti z dobrodružství a nových věcí (Costa & McCrae, 1992).

Psychografická segmentace se vyskytuje i ve výzkumech. Například Zarouali a spol. (2022) při tvorbě personalizaci politických reklam na základě extraverte a introverze zjistili výrazně vyšší vliv v porovnání s generickou reklamou. S. C. Matz a spol. (2024) zjistili podobně velký efekt u personalizovaných reklam na spotřební zboží, které byly tvořeny na základě zákaznických rysů z pětifaktorového modelu osobnosti. Jeden z nejrozsáhlejších výzkumů na cílení pomocí rysů osobnosti provedených na reálném trhu uskutečnili Matz a spol. (2017), kteří vytvořili osobnostní profily pro 3,5 milionu uživatelů na základě dat získaných prostřednictvím sociální sítě Facebook, a na základě těchto profilů jim doručovali různé typy reklam. Výsledky tohoto experimentu ukázaly, že reklamy, které byly přizpůsobeny na základě rysů extraverte a otevřenosti a doručeny lidem se stejným osobnostním profilem, vedly k až 40% nárůstu kliknutí na reklamu a k 50% zvýšení nákupů ve srovnání s reklamami, které nebyly personalizované nebo byly zaměřeny na odlišné osobnostní rysy.

1.4.1.5. Ideologická segmentace

Ideologická segmentace rozděluje zákazníky podle jejich politických postojů a etických hodnot. Tento typ segmentace vychází z poznatku, že názory jednotlivce na společenské či politické otázky zásadně formují jeho postoje jak k politickým, tak i konzumním značkám. Tento druh segmentace může být zejména efektivní v případě názorově polarizovaných trhů, kde poměrně velké segmenty lidí mohou sdílet společné morální postoje a pohledy na svět.

Kromě klasické politické orientace může segmentace vycházet i z etických a morálních ideologií. Například S. C. Matz a spol. (2024) využil morálních základů k přizpůsobení politických sdělení týkajících se klimatických opatření. K segmentaci využil dotazník kvantifikující individuální rozdíly v morálních úsudcích pomocí v rámci 5 dimenzí – věrnost, péče, spravedlnost, nevinnost a autorita (Graham et al., 2013). V rámci studie byly účastníkům prezentovány politické projevy hájící opatření na ochranu klimatu, které byly uzpůsobeny právě těmto morálním základům. Například sdělení přizpůsobené účastníkovi s vysokým morálním základem spravedlnosti mohlo znít takto: „*Věříte ve spravedlivý svět pro všechny? Cítíte silnou odpovědnost za to, aby měl každý dostupný čistý vzduch, čistou vodu a zdravé životní prostředí?*“ (S. C. Matz et al., 2024, str. 5). Tento přístup vychází z

morálních hodnot jednotlivce, aby sdělení bylo přesvědčivější a odpovídalo jeho etickému rámci.

1.4.1.6. Kulturní segmentace

Kulturní segmentace vychází z předpokladu, že základní lidské hodnoty a normy vychází z kulturního prostředí jednotlivce a výrazně ovlivňují jeho spotřební chování. Kulturní segmentace v praxi slouží jako nástroj pro identifikaci odlišných segmentů v kulturně diverzifikovaných trzích. Jak uvádí Štetka a Grisáková (2022) teoretickým základem pro kulturní segmentaci se staly Hofstedeho kulturní dimenze (Hofstede, 2011), jako je míra individualismu versus kolektivismu, vyhýbání se nejistotě nebo mocenský odstup. Tyto dimenze se využívají k pochopení rozdílů ve spotřebitelském rozhodování mezi kulturami a k predikci preferencí cílových skupin v různých regionech. Kulturní segmentace může být založena také na etnické příslušnosti, kulturním dědictví nebo migračním pozadí.

1.4.1.7. Kontextuální segmentace

Kontextuální segmentace rozděluje spotřebitele do skupin podle konkrétních situačních faktorů, které by mohly ovlivnit rozhodovací podstatu jejich nákupního rozhodování. Jedná se tak například o personalizaci na základě dynamických situačních proměnných ovlivňující spotřebitelské rozhodování jako úmysl za nákupem (dárek vs. osobní potřeba), období nákupu (zima vs. léto), nebo například svátky a čas (Faraone et al., 2010). V praxi pak může například personalizační systém využívající kontextuální segmentaci vyhodnotit, že se zákazník právě nachází v oblasti s vysokými teplotami, může mu zobrazit reklamu na studené nápoje. Kontextuální segmentace je proto zvláště účinná v prostředích, kde je možné data získávat a interpretovat v reálném čase, například díky použití počítačového vidění, GenAI nebo interaktivních digitálních kanálů.

1.4.1.8. Segmentace podle benefitů

Tento segment rozděluje zákazníky podle přínosů, které od produktu nebo služby očekávají. Na rozdíl od ostatních segmentací není dáván důraz na zákazníka jako takového, ale spíše na důvody, proč si produkt vybírá. Mezi typické příklady vyhledávaných benefitů se řadí například cena, kvalita, komfort, ekologičnost, nebo rychlost doručení produktu nebo služby. Výzkumy ukazují, že zákazníci často hledají jak utilitární přínosy (např. úspora peněz, funkčnost), tak hedonické přínosy (např. potěšení, estetický zážitek), a že tyto preference lze využít k vytvoření přesně zacílených sdělení (Tsenov, 2013)

1.4.1.9. Více proměnná segmentace

Tento druh segmentace zahrnuje propojení dvou či více druhů výše uvedených typů segmentačních dat. Zatímco tradiční segmentace pracuje často pouze s jedním rozměrem (např. věk nebo pohlaví), více proměnný přístup umožňuje současně zohlednit například demografická, behaviorální a psychografická data, a odhalit tak komplexnější vzorce spotřebitelského chování. Tato metoda se stala často využívanou s rozvojem datové analytických nástrojů, které i v kombinaci nestrukturovaných velkých dat dokáží najít vzorce a struktury využitelné pro segmentaci trhu.

K tomuto přístupu, získávání vhledů skrze analýzu jak strukturovaných, tak nestrukturovaných dat, se pojí termín *data mining* (vytěžování dat). Kučerová termín definuje jako „technologie vyhledávání, modelování a prezentace předem neznámých informací, případně znalostí a vztahů mezi daty v rozsáhlých databázích a datových skladech. [...] Využívají se techniky umělé inteligence (neuronové sítě, rozpoznávání, samoučící se algoritmy), jež mohou být kombinovány s technikami statistického a matematického modelování (klasifikační pravidla nebo stromy, regrese, shluková analýza) a s nástroji OLAP.“ (2003).

Do kategorie více proměnné segmentace spadá i obrazová inferenční personalizace, která je použita v rámci výzkumné části této práce. Všechna segmentační data jsou v tomto případě agregována z výstupů vizuálních senzorů – tedy obrazu zákazníka v daném okamžiku. Z něj systém pomocí počítačového vidění a modelů strojového učení odhaduje demografické znaky (např. věk, pohlaví), psychografické indikátory (např. styl oblečení či zájmy) a behaviorální projevy (např. držení košíku, interakce se zbožím). Nejde tedy o nový typ segmentace, ale o inovativní způsob, jak klasické segmentační proměnné odvodit v reálném čase z vizuálních dat bez potřeby aktivního zapojení zákazníka.

Teoreticky by větší množství informací o příjemci mělo vést k relevantnější komunikaci. Studie, zkoumající mikrotargeting v politické komunikaci, však zjistila, že průměrná přesvědčovací převaha mikrotargetingu nad generickým šířením sdělení byla kvalitativně nejvyšší, když byla sdělení zaměřena pouze na jednu proměnnou, na rozdíl od případů, kdy byla sdělení zaměřena na dva nebo čtyři (Tappin et al., 2023). To naznačuje, že jednodušší strategie cílení, například založené na jedné proměnné, jako je stranická příslušnost nebo ideologie, byly při vytváření persvazivního dopadu účinnější. Je nutno podotknout, že se tato studie nezaměřila na generování personalizovaných zpráv pro jednotlivé účastníky, ale spíše na jejich cílení.

1.4.2. Sběr a struktura dat

Metody sběru dat lze z pohledu zapojení cílového uživatele či zákazníka dá rozdělit na explicitní a implicitní. Explicitní sběr dat znamená, že subjekt vědomě a přímo poskytuje informace například skrze registrační formuláře, dotazníky, uživatelské ankety či preference, které si uživatel sám nastaví v profilu (např. oblasti zájmu, věk, pohlaví). Explicitně lze získat zejména demografická, psychografická či ideologická data, kdy dotazníky mohou mapovat třeba osobnostní rysy (např. Big Five) či hodnotové postoje. Výhodou explicitních dat je jejich transparentnost a strukturovanost, kdy zákazník vědomě poskytuje data většinou v jasně definovaném formátu. Nevýhodou je jejich omezené množství a vypovídající hodnota, kdy zákazníci nejsou ochotni ani schopni explicitně poskytnout například informace o svých nákupech či motivacích.

Proto se personalizace opírá také o implicitní sběr dat, kdy se informace získávají pozorováním uživatele při interakci se službou. Implicitní data zahrnují právě behaviorální záznamy (informace o prokliku, zobrazených položkách, času stráveném u obsahu), ale i odvozené metriky z jednání uživatele, kdy personalizační systém implicitně usoudí zájem o téma, o kterém uživatel často čte články, a to i přesto, že to explicitně neuvedl. Podobný princip implicitního získávání dat využívá i obrazová inference využitá v praktické části této práce, kdy zákazník neposkytl přímo svá data, ale systém je odvodil z vizuálního záznamu.

Implicitní sběr dat probíhá často na pozadí, bez aktivního zapojení subjektu, například prostřednictvím cookies sledujících pohyb na webu, analytických nástrojů monitorující uživatelské chování, senzorů, nebo nástrojů strojového učení, které analyzují obsah příspěvků uživatele na sociálních sítích. Implicitní data mívají méně strukturovanou podobu typicky se jedná o volné texty, seznamy zhlédnutých produktů, geografické souřadnice pohybu, senzorem naměřené hodnoty atd., tedy data, která vyžadují další zpracování a interpretaci.

2. Praktická část

V předešlých částech práce byly detailně popsány a definovány základní funkční principy personalizace reklamního sdělení, technologií umělé inteligence, psychologických mechanismů rozhodování a dat. Tyto koncepty byly následovně zasazeny do praxe marketingové komunikace. V rámci praktické části této práce se budu o ukotvené teoretické poznatky opírat a navrhnu systém pro tvorbu dynamické hyper-personalizované reklamy pomocí nástrojů umělé inteligence v prostředí fyzických prodejen. Tato práce svou přidanou hodnotu nese nejen v návrhu systému jako modelové řešení, ale hlavně v jeho reálné tvorbě, implementaci a experimentálního testování funkčního systému v terénu.

Tato část práce se bude postupně věnovat nejprve návrhu a popisu architektury systému včetně zapojení umělé inteligence do různých komponent (percepční, inferenční, generativní a koordinační), na které bude navazovat definice samotného výzkumného problému, vymezení cílů výzkumu a formulace výzkumných otázek. Následně bude popsána metodologie experimentu zahrnující návrh designu, sběr a čištění dat a použité metody analýzy. Praktická část bude zakončena analýzou výsledků, ověřením stanovených hypotéz a diskusí o praktických implikacích nasazení takového systému v reálném prostředí maloobchodních prodejen.

2.1. Návrh systému pro dynamickou hyper-personalizaci

2.1.1. Popis architektury systému

Pro dosažení dynamické hyper-personalizace reklamního sdělení ve fyzickém obchodě je navržen systém skládající se z několika spolupracujících komponent: lokální percepční komponenty (počítač a vizuální senzor), cloudová inferenční komponenta (logika v rozhodování), cloudová generativní komponenta (LLM), databáze a výstupní komponenta (zobrazení vizuálního výstupu).

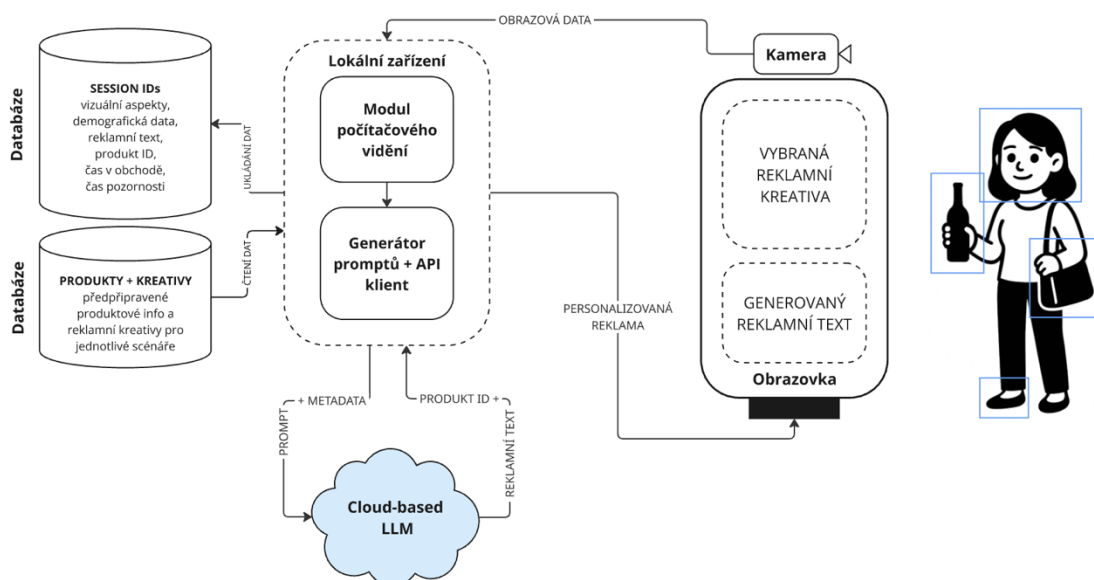


Schéma 5 – Architektura systému dynamické hyper-personalizace v retailu

2.1.1.1. Percepční vrstva

Hlavním vstupním bodem systému je kamera umístěná u reklamního displeje, která kontinuálně snímá prostor před obrazovkou. Hlavní funkcí senzoru je detekce přítomnosti zákazníka a poskytování obrazových dat k analýze. Tento krok odpovídá první fázi procesu personalizace podle modelu Kushnarevycha a Kollárové (2023) – tedy získávání dat o zákaznících.

Lokální zařízení je hlavní komponentou percepční vrstvy, která pomocí algoritmů počítačového vidění analyzuje získaný obraz. Pro popisovanou architekturu systému jsou využívány algoritmy počítačového vidění zaměřené na detekci obličejů a objektů, odhad demografických znaků a emocí, detekci osobních předmětů a odhad pozic těla. Pro určení pozornosti se využívá kombinace lokalizace a sledování objektů v čase. Cílem této analýzy je určit přítomnost zákazníka v prodejně, lokalizovat ho v prostoru k určení úhlu pohledu kvůli výpočtu času pozornosti a odhadnout demografické znaky (např. věk, pohlaví), psychografické indikátory (např. typ oblečení, osobní předměty) a behaviorální projevy zákazníků (např. držení košíku, interakce se zbožím).

Využití lokálního zařízení pro obrazovou analýzu minimalizuje, jak odezvu získaných výsledků, tak riziko úniku dat a zároveň zjednodušuje splnění požadavků na soukromí a ochranu osobních údajů (Andriulo et al., 2024).

2.1.1.2. Inferenční vrstva

Inferenční vrstva tohoto systému má na starosti propojení všech sesbíraných relevantních vstupů a na jejich základě automatizovat personalizační rozhodnutí. První komponentou je lokální algoritmus skládající získaná demografická a další kontextuální data z vizuální analýzy do unikátního promptu. Tento profil je dále rozšířen o informace ze statické databáze produktů. Databáze obsahuje předem definovaný seznam dostupných produktů, přičemž každý záznam zahrnuje podrobná metadata, ze kterých bude další komponent inferenční vrstvy vycházet.

- **Cílové demografické skupiny** (např. věkové rozmezí a pohlaví),
- **Vizuální spouštěče** (např. oblek, sportovní obuv, sluneční brýle),
- **Potřeby zákazníků** (např. regenerace vlasů, ochrana před sluncem),
- **Hodnoty/výhody produktu** (např. zvýšení lesku vlasů, hydratace pokožky),
- **Faktická data** (např. složení, účinky, měřená efektivita).

Tato detailní produktová metadata slouží jako stavební kámen pro inferenční a generativní vrstvy systému, které z nich získají dostatečný kontext k co nejpřesnějšímu rozhodnutí o produktu a jaká reklamní zpráva bude zákazníkovi nabídnuta. Lokální zařízení pak takto zkompletovaná data posílá skrze API do velkého jazykového modelu umístěného na serveru (cloud-based LLM).

Cloud-based LLM v této systémové architektuře plní funkce jak inferenční, tak i generativní. Inferenční funkce označuje rozhodovací schopnost modelu na základě vstupních strukturovaných metadat o zákazníkovi a dostupných produktech vyhodnotit jejich nejvhodnější průsečík. Tato funkce je řízená personalizovaným promptem, který formuluje konkrétní zadání a zaměřuje široké schopnosti velkého jazykového modelu na specifický účel analýzy kontextu a generování personalizovaného sdělení.

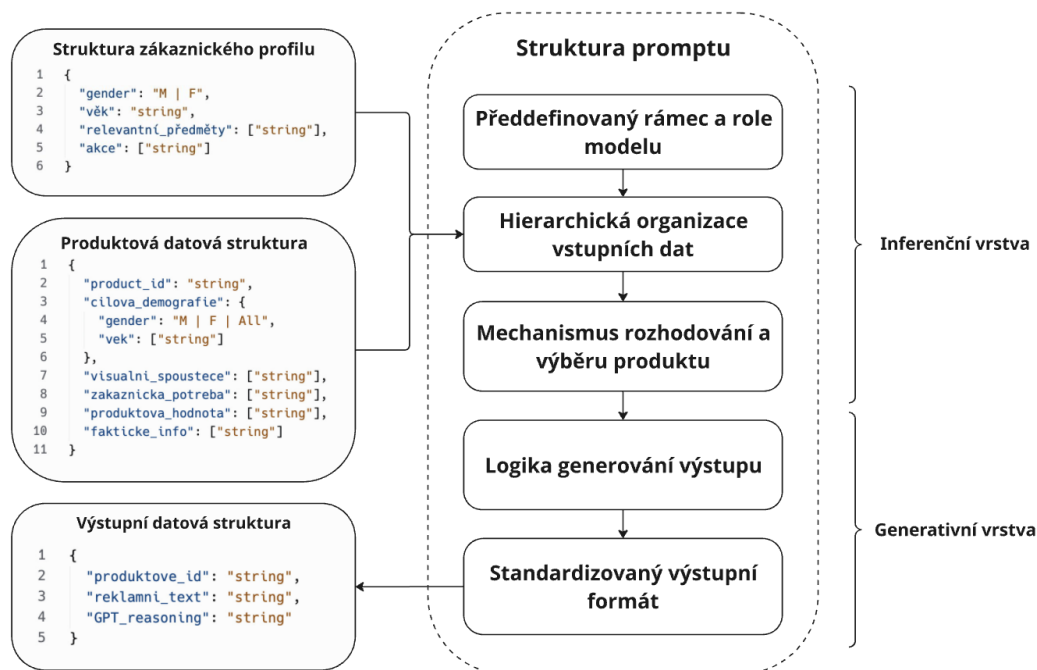


Schéma 6 – Struktura systémového promptu pro LLM

Struktura systémového promptu inferenční vrstvy reflektuje následující logiku (viz. Schéma 6):

1. Předdefinovaný rámec a role modelu

Hned na začátku prompt explicitně nastavuje roli modelu: „vystupuje jako marketingový agent, jehož úkolem je analyzovat zákaznický profil a na jeho základě generovat personalizovaný obsah.“ Tím se zužuje obecný rámec LLM na konkrétní kontext a se snižuje pravděpodobnost nerelevantního rozhodování či generování.

2. Hierarchická organizace vstupních dat

Metadata o zákaznickém profilu (pohlaví, věk, styl oblečení, přítomné objekty, akce, kontext) jsou systematicky uspořádána a interpretována jako podklady pro inferenční rozhodování. Prompt tímto způsobem simuluje proces běžné analýzy cílového zákazníka pro tvorbu marketingových strategií.

3. Mechanismus rozhodování a výběru produktu

Při výběru nejvhodnějšího produktu je model veden k tomu, aby porovnával dostupné produkty s výsledkem zákaznické analýzy volil mezi dostupnými produkty na základě kombinace demografické shody, vizuálních indikátorů psychografie, nebo jiných kontextuálních indicií.

2.1.1.3. Generativní vrstva

Generativní funkce LLM komponenty má podle názvu za cíl samotné generování hyperpersonalizované reklamy. K tomu využívá výstupní data percepčních a inferenčních analýz z minulých vrstev. Logika tohoto procesu je definována pomocí druhé části systémového promptu (viz. Schéma 6):

4. Logika generování výstupu

Prompt dále definuje dvě roviny personalizace. Základní personalizace je založena na přizpůsobení reklamního sdělení podle demografických informací o zákazníkovi (věk a pohlaví). To se na vygenerovaném sdělení projevuje především na volbě tématu sdělení a celkového stylu oslovení. Například mladší zákazníci dostanou dynamičtější a energičtější tón („Objevte eleganci s naší pánskou toaletní vodou!

Dodává energii a sebejistotu.“), zatímco starší cílové skupiny mohou být oslovovány klidnějším a autoritativnějším stylem.

Druhá úroveň personalizace se zaměřuje na využití kontextuálních informací získaných z inferenčních analýzy LLM (předměty, styl oblečení, chování). Tato personalizace umožňuje jemnější ladění pomocí použitých apelů a motivací, například druhá úroveň personalizace využívá kontextuální informace získané z inferenční analýzy (předměty, styl oblečení, akce zákazníka). Například pokud je detekována únava (kruhy pod očima), reklama se zaměří na benefity obnovy vzhledu („Zbavte se unaveného vzhledu! Oční sérum hydratuje a zpevňuje pleť kolem očí.“), zatímco při detekci sportovního stylu může být použit apel na aktivní životní styl. Modelu mohou být v této části promptu také definována stylistická a obsahová pravidla generovaného sdělení jako komunikační tón značky, rámcování sdělení, nebo psychologické apely a přesvědčovací metody.

5. Standardizovaný výstupní formát

Výsledné reklamní sdělení je vráceno v přesně definované JSON struktuře, která umožňuje snadnou integraci výstupu do následných částí systému (např. dynamické zobrazení na digitální obrazovce) a zároveň zjednodušuje analýzu dat pro případné budoucí ladení modelu.

2.1.1.4. Výstupní vrstva

Výstupním médiem je digitální obrazovka, která zobrazuje výslednou personalizovanou reklamu. Reklama je složena z předem připravené vizuální kreativy, která je na základě výběru optimálního produktu (produkt ID) extrahovaná z databáze, a dynamicky generovaného textu přizpůsobeného danému zákazníkovi. Takto hyper-personalizovaná reklama je v bodu generování okamžitě zobrazena na digitální obrazovce ve fyzickém obchodě. Právě díky doručování v reálném čase a ve fyzické lokaci má tato reklama

potenciál zachytit zákazníka v místě prodeje a ovlivnit jeho nákupní chování. Pokud by například kamera detekovala změnu (příchod jiného zákazníka), obsah se opět dynamicky přizpůsobí.

Tento celek tedy funguje jako dynamický cyklus – kamera kontinuálně snímá prostor před obrazovkou, modul počítačového vidění vyhodnocuje přítomnost zákazníka a jeho pozornost, analyzuje vizuální atributy zákazníka a posílá je do LLM pro další zpracování, LLM určí optimální produkt a vytvoří personalizovaný obsah, který je obratem prezentován. Systém dále využívá i podpůrné komponenty jako je datové úložiště pro ukládání anonymizovaných zákaznických dat (demografie, čas pozornosti, čas v obchodě, výše nákupu apod.), které má potenciál v další optimalizaci personalizačního modelu za pomoci zpětnovazebného učení. Primární čtyři komponenty – percepční, inferenční, generativní a výstupní – však tvoří základ architektury navrhovaného systému.

2.2. Experimentální ověření systému v retailu

2.2.1. Definice výzkumného problému

Personalizace marketingové komunikace se již od prvopočátku obchodních vztahů ukazuje jako účinná strategie pro efektivnější oslovení zákazníků. Po nástupu digitálních médií se ale její výzkum omezil na on-line prostředí, ve kterém se začala personalizace zdokonalovat. Řada studií potvrdila silnější zákaznickou odezvu na personalizované a cílené sdělení a to v prostředí sociálních sítí (S. Matz et al., 2017; Walrave et al., 2018), e-mail marketingu (Grbovic et al., 2015), nebo streamovacích platforem (Goli et al., 2025). poznatky z těchto studií jasně ukazují, že relevantně zacílený obsah zaujme zákazníka a může zlepšit jeho nákupní chování v prospěch značky.

Tyto studie však řeší personalizaci specificky v kontextu digitálních médií a mezi výzkumem týkající se účinků personalizace v prostředí fyzického retailu a digitálních médií tak vzniká dosud nevyplněná výzkumná propast. Právě možnost generalizace efektu personalizace na multikanálový prodej není dosud dostatečně prozkoumána a rozdíl mezi vnímáním personalizované komunikace v digitálním prostředí a přímo v kamenné prodejně není jasný. Fyzický retail představuje oproti digitálnímu prostředí velmi odlišný kontext, ve kterém nehrají roli jen odlišné smyslové vjemy, ale taky jiné typy psychologických mechanismů než v osobním digitálním světě zákazníka. Účinnost personalizace zde tedy nelze automaticky odvodit z poznatků minulých studií.

Právě od této identifikované výzkumné mezery se odvíjí i výzkumný problém této práce a zabývá se zapojením systému hyper-personalizované reklamy do prostředí reálného kamenného obchodu. Obecnějším cílem je ověřit, zda dynamická personalizace řízená nástroji umělé inteligence může v kontextu reálného kamenného obchodu zvýšit zaujetí zákazníků a zároveň pozitivně ovlivnit jejich nákupní rozhodování, obdobně jako tomu je v online prostředí. Kromě pokusu o vyplnění této mezery reaguje formulace výzkumného problému také na velice aktuální posun ve schopnostech velkých jazykových modelů a generativní umělé inteligence, který se podepsal i na možnostech personalizace.

Potvrzují to i nejnovější studie, které demonstrují zcela nové možnosti škálování hyper-personalizované komunikace skrze LLM modely. Matz et al. (2024) například zjistili, že zprávy personalizované pomocí modelu ChatGPT mají výrazně vyšší persvazivní účinek v porovnání s nepersonalizovaným sdělením napříč různými oblastmi. Podobně i další autoři (Salvi et al., 2024; Shin & Kim, 2024) zdůrazňují, že využití velkých jazykových modelů v marketingové komunikaci má potenciál výrazně zvýšit relevanci a účinnost oslovení zákazníka. Dynamický hyper-personalizovaný systém na bázi LLM není v tomto experimentu integrován jen jako nástroj ověření účinku personalizace ve fyzickém retailovém prostředí, ale zároveň jako demonstrace nově vznikající úrovně interakce se zákazníkem. Tento výzkum tak přináší přínos ve dvou úrovních – zaplňuje dosud neprozkoumanou výzkumnou mezeru v oblasti off-line personalizace a zároveň testuje praktickou realizovatelnost systémů, které by mohly reprezentovat budoucnost personalizované komunikace.

2.2.2. Cíle výzkumu a stanovení hypotéz

Hlavním cílem tohoto výzkumu je prověřit a popsat efekt hyper-personalizované reklamy v reálném prostředí off-line retailu na zákaznické chování. Tímto výzkum navazuje na již existující poznatky ze studií efektů personalizované komunikace v digitálním prostředí a vyplňuje tak zmíněnou empirickou mezeru. Vedlejším cílem je také detailněji prozkoumat mechanismy tohoto efektu a případné moderační vlivy demografických faktorů na dobu zaujetí a pravděpodobnost nákupu. Tyto výzkumné góly se promítají do formulace následujících čtyř hypotéz a jedné výzkumné otázky.

První hypotéza byla stanovena na základě reportovaných konkurenčních výhodách personalizované reklamy v on-line prostředí ve výše zmíněných studiích. Ty prokázaly nárůst v relevanci a schopnosti naplňovat potřeby zákazníka oproti genericky cíleným reklamám (Walrave et al., 2018), ale také nárůst v zájmu o interakci zákazníků (uživatelů) (Goli et al., 2025). Proto očekáváme překlopení tohoto pozitivního efektu na míru zaujetí reklamou, která se v tomto experimentálním designu promítne na delším sledování hyper-personalizované reklamy.

H1: Vystavení hyper-personalizované reklamě povede k delšímu průměrnému zaujetí zákazníků než při vystavení generické reklamě.

Díky poskytnutí relevantnější reklamy s personalizovaným doporučením by mělo u zákazníků dojít k posílení nákupního úmyslu. Tento efekt personalizovaného reklamního sdělení na samotné nákupní chování popsaly opět i studie z on-line prostředí, které doložily signifikantní nárůst v konverzním poměru (Grbovic et al., 2015; S. Matz et al., 2017). Na základě těchto poznatků byla formulována druhá výzkumná hypotéza.

H2: Vystavení hyper-personalizované reklamě zvýší pravděpodobnost nákupu doporučeného produktu oproti vystavení generické reklamě.

Další hypotéza byla formulována na základě tradičních modelů reklamní konverze (např. AIDA), které udávají pozornost (attention) jako základní stavební kámen pro konverzi (action), ale je zároveň podpořena aktuálními výzkumy. Například analýza ekonometrického datového setu složeného z 141 značek ukázala, že téměř 98% variace v zisku je vysvětleno pozorností (Basset & Rooney, 2024). To potvrzuje, že pozornost je silným prediktorem zisku. Kumulativní efekt krátkých interakcí popisuje studie Havas Media Network, Lumen Research a Brand Metrics (2024). Podle jejich zjištění může i jedna sekunda zvyšovat povědomí o značce, dvě sekundy mohou vést ke změně zákaznických preferencí a přibližně deset sekund pozornosti může zvýšit záměr nákupu. V tomto kontextu předpokládáme, že zákazníci, kteří budou dávat reklamnímu sdělení pozornost delší dobu, budou častěji konvertovat než ti, kteří reklamní sdělení pouze krátce zaregistrují nebo ho zcela minou.

H3: Vyšší doba zaujetí zákazníka jakoukoli reklamou zvyšuje obecnou pravděpodobnost nákupu.

Následující hypotéza propojuje výše uvedené předpoklady, podle kterých by hyper-personalizace měla částečně působit na celkový nákup tím, že upoutá pozornost zákazníka na delší dobu, což následně zvyšuje pravděpodobnost nákupního rozhodnutí.

H4: Vystavení zákazníka hyper-personalizované reklamě vede oproti generické reklamě k (H4a) zvýšené pravděpodobnosti obecného nákupu a (H4b) tento vztah je částečně mediován délkou zaujetí.

Na závěr bude tento výzkum prověřovat případné rozdíly napříč demografickými skupinami ve výše popsaných efektech. Z existujících studií personalizace víme, že účinnost on-line reklamy se může lišit napříč věkovými skupinami či pohlavím (Boerman et al., 2017). Tyto rozdíly mohou být v případě věku dané například jiným přístupem k datovému soukromí.

VO1: Ovlivňují věk a pohlaví zákazníka účinek generické a hyper-personalizované reklamy na (VO1a) míru zaujetí a (VO1b) jeho pravděpodobnost nákupu?

2.2.3. Metodologie výzkumu

2.2.3.1. Design výzkumu a experimentální uspořádání

Pro ověření výše uvedených hypotéz byl navržen mezisubjektový experiment porovnávající reakci účastníků experimentu na dvě podmínky v reálném prostředí kamenných prodejen. Konkrétně se jednalo o takzvané A/B testování v rámci čtyř pražských obchodů českého výrobce kosmetiky. Experiment probíhal za živého provozu prodejen po dobu dvou týdnů, během nichž byly na reklamních obrazovkách střídány dvě experimentální podmínky: generický reklamní obsah a hyper-personalizovaný reklamní obsah generovaný navrhnutým systémem. Pro účely jednodušší navigace v praktické části této práce se budu na experimentální podmínky odkazovat jako **HP** (hyper-personalizovaná reklama) a **G** (generická reklama). Základní rozdíly mezi experimentálními podmínkami byly následující (detailní popis viz. kap. Příprava stimulů):

Stimuly generické reklamy (G) byly předem definovány a zobrazovány náhodně bez ohledu na to, kdo se před obrazovkou nachází. Video obsah umístěn na pozadí byl náhodně vybírán z databáze předem připravených reklamních spotů. Tato databáze obsahovala 11 unikátních

videí pro 11 odlišných produktů. Textový obsah, umístěn na videu byl univerzální, cílený na široké publikum (viz. Obrázek 1).

U stimulů hyper-personalizovaná reklamy (HP) se obsah personalizoval na dvou úrovních. Video obsah byl vybírán ze stejné databáze 11 spotů pro 11 odlišných produktů, ale jeho selekce byla cílená a probíhala na základě inferenční vrstvy systému. Textový obsah nebyl jako u generické reklamy předem definovaný, ale byl generován v reálném čase za pomoci LLM na základě dostupných informací o zákazníkovi (viz. kap. Návrh systému pro dynamickou hyper-personalizaci)



Obrázek 1 – Ukázka rozložení obrazovek v obchodech 1 a 3

Cílem této experimentální architektury bylo porovnat chování zákazníků ve dvou odlišných experimentálních podmínkách (HP vs. G) v reálném prostředí fyzické prodejny. Po vstupu zákazníka do zorného úhlu kamery byl systém automaticky aktivován. Bez ohledu na to, zda byl v daný den aktivní režim generické (G) nebo hyper-personalizované (HP) reklamy, percepční vrstva systému (viz kapitola Návrh systému pro dynamickou hyper-personalizaci)

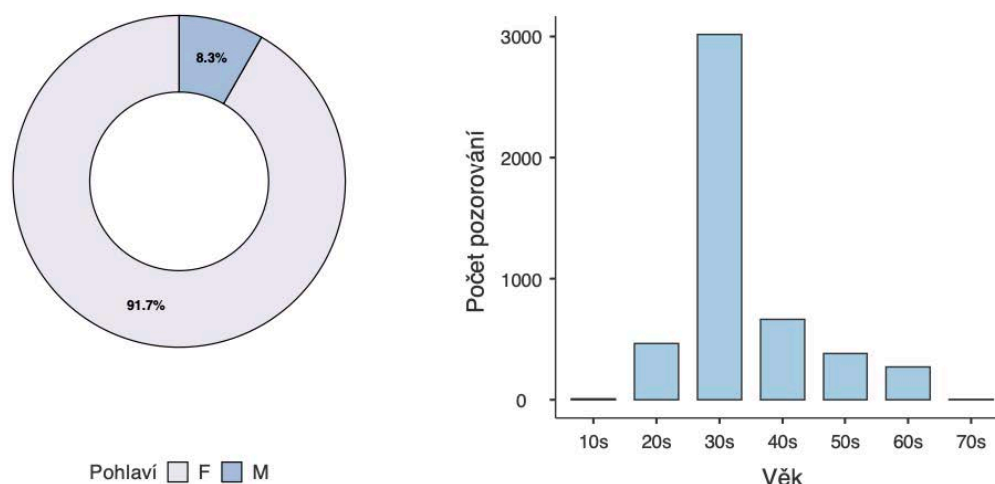
začala analyzovat vizuální atributy zákazníka a zároveň měřit klíčovou proměnnou experimentu – zaujetí zákazníka. To umožnilo, jak vyhodnocení rozdílů v míře zákaznického zaujetí mezi generickou a hyper-personalizovanou reklamou, tak určení vlivu demografických proměnných na nákupní chování.

Pro zajištění interní validity experimentu, byly provedeny kroky s cílem odfiltrování nežádoucích činitelů, které by mohli nekontrolovatelně ovlivňovat závislou proměnnou. Kvůli terénní podstatě tohoto experimentu, bylo nutné kontrolovat časové a lokační zkreslení. To bylo zajištěno střídáním podmínek G/HP napříč jednotlivými prodejny a časovými intervaly. Logika rozdělení podmínek byla nastavena následovně: prodejny s identifikačním číslem 2 a 3 zahájily experiment v první den vystavením zákazníků hyper-personalizované reklamě a následně střídaly podmínky každý den. Prodejny 1 a 4 naopak začínaly s generickou reklamou a rovněž podmínky denně střídaly. Díky čtrnáctidenní délce sběru bylo možné získat data pro obě experimentální podmínky (G/HP) v rámci každé prodejny i pro každý den v týdnu. To umožnilo vyrovnat vliv specifik jednotlivých prodejen (např. rozdílná frekvence zákazníků či odlišné prostředí) i vliv denní doby či dní v týdnu (např. víkendové nákupní špičky).

Dalším z rizik pro interní validitu byl například vizuální efekt samotné změny reklamy, bez ohledu na úroveň personalizace. Tento vliv byl mitigován skrze přes nastavení podobných vizuálních změn pro obě experimentální skupiny. Vizuální stimul u skupiny vystavené generické reklamě byl nastavena tak, aby se videa střídala náhodně a vždy po přehrání jednoho reklamního spotu trvajícího průměrně 20 sekund. Tato vizuální frekvence zhruba odpovídala frekvenci pro hyper-personalizovanou reklamu, která se spustila průměrně 6 sekund po prvním zachycení pozornosti a vydržela na obrazovce do doby, kdy zákazník vyšel ze zorného pole snímající kamery. To bylo podle sesbíraných dat v průměru 35 sekund.

2.2.3.2. Popis výzkumného souboru

V rámci 14denního experimentu se podařilo získat celkem 8 176 záznamů o zákaznických interakcích napříč čtyřmi prodejny. V kontextu tohoto experimentu jsme považovali každou interakci s obrazovkou jako jednoho unikátního zákazníka. Tento přístup byl zvolen v zájmu ochrany soukromí návštěvníků, protože systém nezaznamenával žádné identifikátory, které by umožnily zpětnou identifikaci jednotlivců. Demografický profil těchto zákazníků odpovídá cílové skupině vybraných obchodů s naměřeným přibližným 91 % zastoupením žen (po zpracování dat viz. kap. Předzpracování dat). Věkové rozpětí zákazníků bylo široké, nicméně dominantní zastoupení měli zákazníci středního věku.



Graf 1 – Demografické rozložení výzkumného souboru

Dle dat z vizuální analýzy se věk zákazníků pohyboval za rozmezí od 10 do 70 let, kdy nejpočetnější věkové skupiny byly v rozmezí 20 až 40 let. Zákazníci ve věku kolem 30 let tvořili 63 % celkového výzkumného souboru. Starší zákazníci (nad 60 let) se objevovali méně často, což může odrážet i běžnou klientelu daného obchodu. Celkově lze říci, že výzkumný soubor zahrnuje převážně mladší a středně věkové dospělé ženy, což odpovídá typické demografii zákazníků vybraných obchodů. Demografické údaje (pohlaví a věk) byly v rámci experimentu získávány u každého detekovaného zákazníka nepřímo skrze

počítačové vidění (viz kap. Návrh systému pro dynamickou hyper-personalizaci). Ačkoli tyto analýzy demografie vychází z pravděpodobnostně založených modelů, poskytují zajímavý pohled do složení výzkumného souboru a mimo personalizaci samotnou umožňují i zkoumat vliv demografických faktorů sledované jevy (viz VO1).


Výzkumný design experimentu umožnil vyváženého rozdělení zákaznických interakcí mezi dvě skupiny, kdy jedna byla vystavená klasické generické reklamě, zatímco pro druhou skupinu byla zobrazována hyper-personalizovaná reklama. Ve skupině s generickou reklamou bylo po ukončení experimentu zaznamenáno celkem 4026 interakcí (49 %) oproti 4150 (51 %) v případě hyper-personalizované reklamy. Po vyčištění datového setu (viz. kap. Předzpracování dat) bylo ve skupině s generickou reklamou ponecháno 2425 interakcí (50 %) a ve skupině vystavené hyper-personalizovanému stimulu 2385 interakcí (50 %).

2.2.3.3. Předzpracování dat

Před samotnou analýzou byl nasbíraný datový set vyčištěn a připraven tak, aby výsledky nebyly zkresleny chybnými či extrémními hodnotami. Nejprve byly odstraněny záznamy, jejichž čas zobrazení reklamy byl nula. K tomuto případu mohlo dojít třeba tehdy, kdy systém detekoval přítomnost osoby v prostoru obchodu, ale nestihl do jejího odchodu již vygenerovat a zobrazit reklamní obsah (typicky velmi krátký průchod zákazníka před obrazovkou). Tento filtr vyřadil z finálního datového setu 3275 záznamů, což může být zapříčiněno buďto výrazným šumem tvořeným procházejícími zaměstnanci, specifickým chováním zákazníků v obchodech, nebo limitem v rychlosti síťové komunikace s LLM.

Tím, že systém je závislý na komunikaci s cloudovým modelem LLM, bylo nutné vzít v potaz také čas odezvy tohoto modulu, který přímo úměrně ovlivňuje rychlost zobrazení reklamy. Pro monitorování situace, kdy výkonnost internetového připojení klesla pod hodnotu umožňující včasné doručení personalizované reklamy, byla vytvořena metrika *LLM odezva*. V případě, že odezva přesáhla 16 sekund, byl záznam považován za nevalidní a vyřazený ze souboru. Tímto sítím se do finálního datového setu nedostalo 142 záznamů.

Podíváme-li se na metriku *LLM odezva* deskriptivně, vidíme, že medián doby od zachycení zákazníka po doručení reklamy není konzistentní mezi lokacemi obchodů. Zatímco ve dvou obchodech se pohybuje kolem 4 sekundy, zbývající dva obchody se pohybovali v rozmezí 6 až 8 sekund. Právě otázka odezva je podrobněji diskutována v kapitole limity výzkumu.



Graf 2 – Deskriptivní histogram LLM odezvy mezi jednotlivými lokacemi

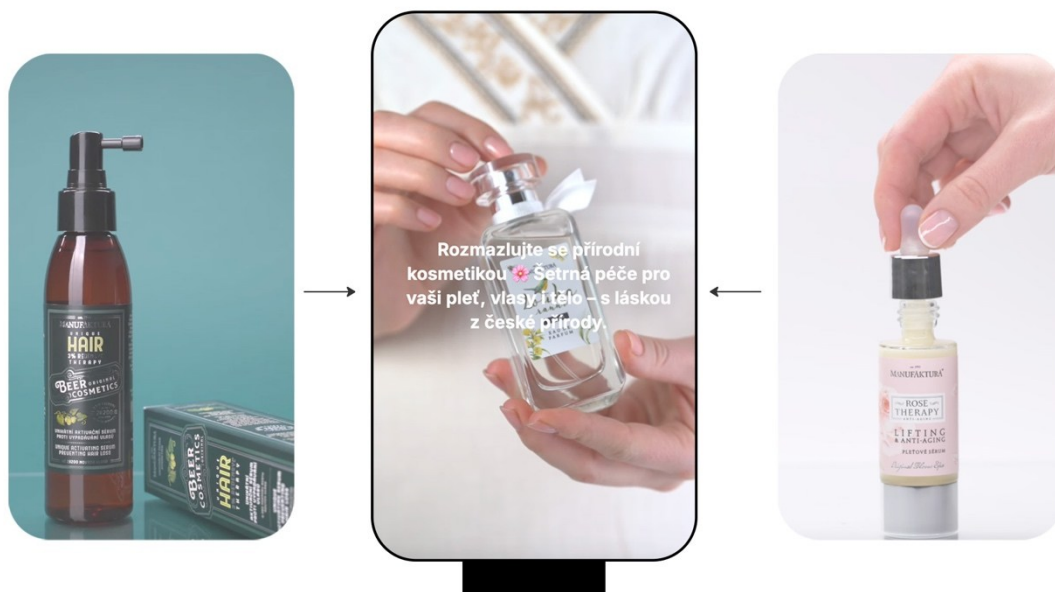
Dále byly naopak odfiltrovány extrémně pozitivně vychýlené hodnoty, kdy délka zaujetí zákazníka přesáhla 120 sekund. Hranice 120 sekund byla stanovena na základě deskriptivní analýzy, která ukázala, že 99 % záznamů obsahuje míru pozornosti pod 84 sekund a extrémně dlouhé časy tak mohly značit neobvyklé situace nesouvisející běžným chováním zákazníka. Typicky mohlo jít o záznam zaměstnance doplňující zboží, záměrné testování systému apod.

Celkově bylo po tomto zpracování vyřazeno 3366 záznamů, což ukazuje na poměrně velký šum způsobený zejména interakcemi, které byly na tolik krátké, že systém nestihl zobrazit reklamu. Odstraněním těchto extrémů se zajistilo, že průměrné hodnoty a statistické testy nebudou neúměrně ovlivněny několika málo atypickými pozorováními.

2.2.3.4. Příprava reklamních stimulů

Pro experiment bylo nutné připravit podklady, které byly systémem použité pro generování dvou typů reklamních stimulů odpovídající oběma podmínkám generické a hyperpersonalizované reklamy. Základem obou typů reklam byly krátké vertikální propagační spoty, které byly vytvořeny pro každý z 11 vybraných produktů separátně. Náhledy spotů pro všechny produkty lze najít v příloze č. 6.

Při generické podmínce byl reklamní obsah složen z náhodně se střídajících propagačních videí z této databáze. To znamená, že systém nezohledňoval žádné informace o aktuálním zákazníkovi a reklamy se střídaly náhodně a mezi všemi dostupnými produkty. K tomuto vizuálnímu obsahu byl přidán také generický reklamní text, navržený tak, aby působil obecně a fungoval u všech z předvybraných produktů. Tento text se při prolínání videospotů neměnil a zůstal tak po celou dobu testování generické reklamy konstantní.



Obrázek 2 – Ukázka zobrazení stimulů generické reklamy

Naopak v podmínce hyper-personalizované reklamy byl využit dynamický personalizovaný systém popsáný v kapitole 2.1, který v reálném čase generoval reklamní sdělení šitá na míru právě přítomnému zákazníkovi. Jakmile kamera a percepční modul detekovaly zákazníka a vyhodnotily jeho základní charakteristiky, předaly tyto informace inferenční a generativní části systému. Výsledkem tedy bylo hyper-personalizované reklamní sdělení, které se zákazníkovi zobrazilo pár sekund po jeho příchodu do obchodu. To se v tomto případě skládalo z reklamního spotu na zvolený nejrelevantnější produkt a unikátního vygenerovaného reklamního textu, vytvořeného na míru zákazníkovi. Stylistická a obsahová pravidla generovaných sdělení byly definovány v systémovém promptu LLM, který byl v případě tohoto experimentu naučen stylu komunikace využitě značky na již existujících textech ze sociálních sítí a webu. Výsledkem jsou tedy hyper-personalizované texty v unikátním tónu značky.



Obrázek 3 – Ukázka zobrazení stimulů hyper-personalizované reklamy

2.2.3.5. Sběr dat a měřené proměnné

Sběr dat probíhal automatizovaně prostřednictvím výše popsaného systému (viz. kap. Návrh systému pro dynamickou hyper-personalizaci). Při každé započaté zákaznické interakci byly

do databáze ukládány relevantní informace o jejím průběhu. Mezi klíčové proměnné, využitě v analýze patřily zejména:

Doba zaujetí zákazníka je základní metrika tohoto experimentu vyjádřena časem, po který se zákazník aktivně díval na reklamní obrazovku. Tato metrika byla měřena v percepčním modulu počítačového vidění skrze analýzu pózy zákazníka včetně úhlu pohledu, kdy se kumulativně zaznamenávala jen v případě aktivního úhlu pohledu směrem k reklamní obrazovce. Doba zaujetí zákazníka je využita pro testování hypotéz H1, H3, H4 a výzkumnou otázku VO1 a tvoří tak základní experimentální proměnnou. Pro účely našeho experimentu předpokládáme, že personalizovaný obsah udrží pozornost déle, pokud lépe rezonuje se zájmy zákazníka.

Demografické charakteristiky zákazníka jako odhadovaný věk a pohlaví jsou sbírány nejen k personalizaci samotné, ale také k ověření výzkumné otázky VO1. Ta se ptá, zda tyto faktory mohou mít měřitelný vliv na zákaznickou míru zaujetí, či na jeho pravděpodobnost nákupu.

Doporučený produkt ukazuje, jaký z databáze 11 produktů byl pro konkrétního zákazníka vybrán inferenční vrstvou systému. Tato informace slouží k zobrazení správné reklamní kreativy, ale také nám umožňuje sledovat, zda toto hyper-personalizované doporučení vedlo ke specifickému nákupnímu chování.

Nákupní chování po zhlédnutí reklamy vyjadřuje, zda zákazník během určené doby po zhlédnutí reklamy uskutečnil nákup. Konkrétně byl nákup definován jako uskutečněná transakce v časovém okně ± 7 minut od dané reklamní interakce, která vychází z kompromisu mezi spodními percentily časových intervalů nákupů a průměrnou dobou strávenou v obchodě (metoda je diskutována v kap. Limity práce a doporučení pro další výzkum). Tato analýza byla možná díky externím datům mapující prodeje ve sledovaných obchodech, laskavě poskytnutá spolupracující značkou kosmetiky. Na základě informací o době prodeje a jeho obsahu byly definovány dvě binární proměnné indikující konverzní výsledek nákupního chování, a to *Nákup doporučeného produktu* a *Nákup jakéhokoliv produktu*. Proměnná *Nákup doporučeného produktu* nabývá hodnoty 1 v případě, že daný

zákazník zakoupil přímo konkrétní produkt, který mu byl v rámci hyper-personalizované reklamy doporučen. Hodnota 0 naopak znamená, že po vystavení reklamě na tento konkrétní produkt si ho zákazník nekoupí. Naproti tomu proměnná *Nákup jakéhokoliv produktu* označuje případy, kdy zákazník uskutečnil jakýkoli nákup během dané návštěvy (1 = nakoupil alespoň jeden produkt, 0 = nenakoupil nic). Tyto dvě proměnné nám umožní rozlišit dva stupně účinku reklamy na nákupní chování, a to jednak efekt na nákup inzerovaného (doporučeného) produktu a druhá dopad na obecnou nákupní aktivitu zákazníka. Pro testování H2 je podstatná proměnná *Nákup doporučeného produktu*, zatímco pro vyhodnocení celkové pravděpodobnosti nákupu a souvislosti se zaujetím využijeme *Nákup jakéhokoliv produktu*.

2.2.4. Metody analýzy

Pro ověření stanovených hypotéz byly využity různé nástroje statistické analýzy odpovídající kvantitativní povaze proměnných v experimentu. K určení vlivu hyper-personalizované reklamy na průměrnou dobu zaujetí zákazníka ve srovnání s vlivem generické reklamy (**H1**), byl využit dvouvýběrový T-test pro dva nezávislé výběry. Ten měl za cíl ověřit, zda se průměrné časy zaujetí ve dvou skupinách signifikantně liší. Před použitím T-testu byla ověřena distribuce dat pomocí testu normality a homogenity rozptylů hlavní závislé proměnné. Shapiro-Wilkův test odhalil výraznou odchylku od normality ($p < .001$) a Leveneho test potvrdil porušení předpokladu rovnosti rozptylů ($p < .001$). Díky vysokému počtu pozorování ($N = 4810$) lze dle centrální limitní věty očekávat, že rozdělení průměrů se bude blížit normálnímu rozdělení a použití T-testu bylo tedy i přes porušení normality považováno za vhodné. Pro ověření robustnosti výsledků byl mimo Welchova t-testu proveden i neparametrický Mann-Whitneyho U test (viz. kap. Vyhodnocení výzkumu).

Hypotéza zabývající se efektem hyper-personalizace na pravděpodobnost nákupu doporučeného produktu (**H2**) a část čtvrté hypotézy zaměřující se na dopad na obecné nákupní chování jako (**H4a**) byly analyzovány pomocí binární logistické regrese. Tato metoda byla zvolena kvůli dichotomické podstatě proměnných mapující nákupní chování zákazníků, a to *Nákup doporučeného produktu* pro H2 a to *Nákup jakéhokoliv produktu* pro

H4a (označuje jakýkoli nákup po zhlédnutí reklamy). Logistická regrese v těchto případech ukazuje vliv experimentálních podmínek na šanci nákupu, která bude pro lepší interpretaci vyjádřena také poměrem šancí mezi změnou nákupního chování v různých podmínkách.

Vztah mezi obecnou dobou zaujetí zákazníka skrze obě experimentální podmínky a pravděpodobností nákupu (**H3**) byl analyzován pomocí dvou nástrojů. Nejprve byla proveden výpočet korelačního koeficientu, který pomohl určit základní vztah mezi dvěma proměnnými. Pro získání pravděpodobnostní interpretace vztahu byla pak využita logistická regrese, u které očekáváme projev délky zaujetí jako signifikantního pozitivního prediktoru pravděpodobnosti nákupu.

Pro ověření mediačního efektu délky zaujetí na obecném nákupním chování po vystavení hyper-personalizované reklamě byl použit regresní model. Nejprve byl analyzován přímý efekt HP experimentální podmínky na obecné nákupní chování vyjádřené proměnnou *Nákup jakéhokoliv produktu* (**H4a**). Následně byl model rozšířen o potenciálního mediátora (délka zaujetí reklamou) pro zjištění jejich vzájemné interakce (**H4b**). Pro hodnocení míry mediace bylo sledováno, zda po přidání mediátoru do modelu klesne přímý efekt experimentální podmínky na nákup a zda je naměřený efekt mediátoru statisticky významný.

Výzkumná otázka zabývající se vlivem demografických údajů jako věková kategorie a pohlaví na míru zaujetí hyper-personalizovanou reklamou (**VO1a**) a na nákupní chování (**VO1b**) byla zodpovězena pomocí dvou statistických metod. Pro VO1a byla využita dvoufaktorová ANOVA, ve které se zkoumal vliv pohlaví a věku na dobu zaujetí zákazníka, s následovnými post hoc testy pro určení zdroje efektu. Pro VO1b pak byly využity dvě statistické metody – chí-kvadrát analýza s doplňujícími post hoc testy pro demografickou proměnnou pohlaví a binomická logistická regrese pro demografickou proměnnou věku. Ta v tomto případě nahradila chí-kvadrát analýzu z důvodů extrémně nízkému počtu záznamů u některých věkových skupin.

K určení statistické signifikace zamítnutím nulové hypotézy byla použita obvyklá hranice $p < 0.05$. K měření velikosti efektu u ANOVA byl využit η^2 (eta-kvadrát), který jehož velikost

je běžně interpretována podle takzvaných Cohenových pravidel znázorněné na stupnici (Miles & Shevlin, 2000):

- $\eta^2 > 0.14$ představuje velký efekt
- $0.14 > \eta^2 > 0.06$ představuje střední efekt
- $0.06 > \eta^2 > 0.01$ představuje malý efekt

Pro vyjádření efektu u T-testů bylo využito Cohenovo d , které je interpretováno následovně (Cohen, 2013):

- Cohenovo $d \approx 0.2$ představuje středně malý efekt
- Cohenovo $d \approx 0.5$ představuje střední efekt
- Cohenovo $d \approx 0.8$ představuje velký efekt

Pro vyjádření efektu u Chi-kvadrát testu bylo využito Cramerovo V , které je interpretováno jako (Cramér, 1999):

- $0.2 > \text{Cramerovo } V$ představuje slabý vztah
- $0.2 < \text{Cramerovo } V < 0.6$ představuje středně silný vztah
- $0.6 < \text{Cramerovo } V$ představuje velmi silný vztah

2.3. Vyhodnocení výzkumu

2.3.1. Vyhodnocení vlivu hyper-personalizace na zaujetí (H1)

T-test pro nezávislé výběry

		Statistic	df	p		Velikost efektu
Doba zaujetí	Student's t	3.11 ^a	4808	0.002	Cohenova d	0.0897
	Welch's t	3.11	4689	0.002	Cohenova d	0.0896
	Mannovo-Whitneyho U	2.78e+6		0.026	Rank biserial correlation	-0.0371

Poznámka. $H_0: \mu_{HP} = \mu_G$

^a Leveneho test je významný ($p < .05$), což naznačuje porušení předpokladu rovnosti rozptylů

Tabulka 1 – Výsledky t-testů a neparametrického testu pro porovnání doby zaujetí mezi podmínkami (H1)

Deskriptiva skupin

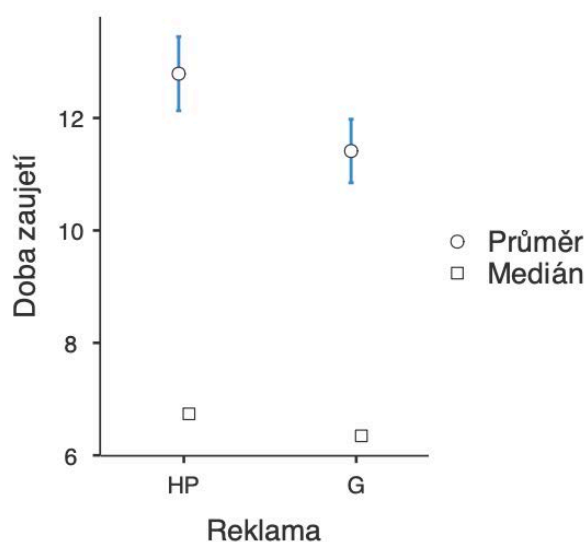
	Skupina	N	Průměr	Medián	SD	SE
Doba zaujetí	HP	2385	12.8	6.74	16.4	0.336
	G	2425	11.4	6.35	14.2	0.288

Tabulka 2 – Deskriptivní statistiky doby zaujetí podle typu reklamy (H1)

Pro ověření hypotézy H1 byla analyzována rozdílná délka zaujetí zákazníků mezi skupinami vystavenými hyper-personalizované (HP) a generické (G) reklamě. Před samotným porovnáním byly testovány předpoklady normality a homogenity rozptylů. Shapiro–Wilkův test odhalil porušení normality ($W = 0.659, p < .001$) a Leveneův test prokázal nerovnost rozptylů mezi skupinami ($F = 20.1, p < .001$). Vzhledem k těmto porušením byl pro analýzu použit Welchův t-test, který je vůči těmto odchylkám robustní.

Výsledky Welchova t-testu odhalily, že účastníci vystavení hyper-personalizované reklamě ($M = 12.8, SD = 16.4$) vykazovali statisticky významně delší dobu zaujetí než účastníci v podmínce generické reklamy ($M = 11.4, SD = 14.2$), $t(4689) = 3.11, p = .002$. Ačkoli velikost efektu byla malá (Cohenovo $d = 0.09$), jedná se o konzistentní a směrodatný posun s očekávaným směr vlivu.

Tyto výsledky **podporují hypotézu H1** o pozitivním vlivu hyper-personalizované reklamy na míru zaujetí spotřebitelů ve srovnání s reklamou generickou. Statisticky významný rozdíl v průměrné době zaujetí naznačuje, že personalizovaný přístup k reklamní komunikaci může účinněji přitáhnout a udržet pozornost zákazníků. Ačkoli efekt velikostně zůstává v mezích malého účinku, v kontextu reálného prostředí s krátkou expoziční dobou reklam může i takto mírné prodloužení pozornosti představovat relevantní výhodu pro efektivitu sdělení.



Graf 3 – Průměrná a mediánová doba zaujetí podle typu reklamy (H1)

2.3.2. Vyhodnocení vlivu hyper-personalizace na nákupní chování (H2)

Měřítko vhodnosti modelu

Model	Odchylka	AIC	R^2_{McF}
1	653	657	0.00107

Poznámka. Modely vypočítané na základě vzorku o velikosti N=4810

Tabulka 3 – Míry vhodnosti regresního modelu pro predikci nákupu doporučeného produktu podle typu reklamy (H2)

Modelové koeficienty - Nákup doporučeného produktu

Prediktor	Odhad	SE	Z	p	Poměr šancí (OR)
Intercept	-4.470	0.194	-23.094	<.001	0.0115
Podmínka:					
G – HP	0.217	0.259	0.835	0.404	1.2419

Poznámka. Odhady představují logaritmické pravděpodobnosti "Nákup doporučeného produktu = 1" vs. "Nákup doporučeného produktu = 0"

Tabulka 4 – Regresní koeficienty modelu testujícího vliv typu reklamy na nákup doporučeného produktu (H2)

Cílem této analýzy bylo ověřit hypotézu H2, která předpokládala, že vystavení zákazníka hyper-personalizované reklamě (HP) zvýší pravděpodobnost nákupu doporučeného produktu ve srovnání s generickou reklamou (G).

K testování byl použit binomický logistický regresní model s dichotomickou závislou proměnnou *Nákup doporučeného produktu* (0 = nákup neproběhl; 1 = nákup proběhl). Prediktorem v této analýze byla experimentální podmínka tedy hyper-personalizovaná, nebo generická reklama (HP / G). Výsledky však neprokázaly statisticky významný rozdíl mezi experimentálními podmínkami ($B = 0.217$, $SE = 0.259$, $Z = 0.835$, $p = .404$). Hodnota poměru pravděpodobnosti ($OR = 1.24$) nebyla podpořena na hladině statistické významnosti a model celkově vysvětloval pouze velmi malý podíl variance výsledku ($R^2_{McF} = 0.00107$).

Na základě těchto výsledků nelze s dostatečnou jistotou tvrdit, že typ reklamy měl vliv na pravděpodobnost nákupu doporučeného produktu a stanovená **hypotéza H2 nemůže** v tomto experimentu být **podpořena**.

2.3.3. Vztah mezi zaujetím reklamou a nákupním chováním (H3)

Měřítka vhodnosti modelu

Model	Odchylka	AIC	R ² _{McF}
1	5558	5562	0.0116

Poznámka. Modely vypočítané na základě vzorku o velikosti N=4810

Tabulka 5 – Míry vhodnosti regresního modelu pro predikci pravděpodobnosti nákupu na základě doby zaujetí (H3)

Modelové koeficienty - Nákup jakéhokoliv produktu

Prediktor	Odhad	SE	Z	p	Poměr šancí (OR)
Intercept	0.7641	0.04286	17.83	<.001	2.15
Doba zaujetí	0.0204	0.00280	7.29	<.001	1.02

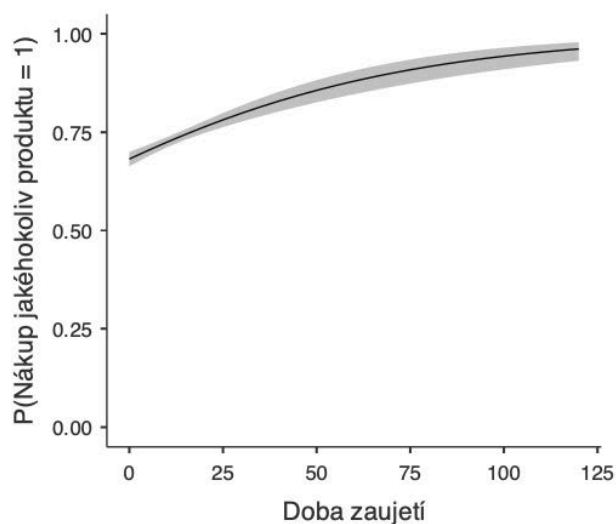
Poznámka. Odhady představují logaritmické pravděpodobnosti "Nákup jakéhokoliv produktu = 1" vs. "Nákup jakéhokoliv produktu = 0"

Tabulka 6 – Regresní koeficienty modelu testujícího vliv doby zaujetí na pravděpodobnost nákupu (H3)

Pro ověření hypotézy H3, která předpokládala, že vyšší doba zaujetí reklamou zvyšuje pravděpodobnost nákupu jakéhokoli produktu, byla použita binomická logistická regrese. Výsledky ukazují, že vztah mezi délkou zaujetí a nákupním chováním je statisticky významný. Koeficient pro dobu zaujetí byl pozitivní a signifikantní ($B = 0.0204$, $SE = 0.00280$, $Z = 7.29$, $p < .001$), přičemž poměr šancí (OR) naznačuje, že s každou další sekundou pozornosti se pravděpodobnost nákupu zvyšuje přibližně o 2 % ($OR = 1.02$). Ačkoli se může tento efekt jevit jako relativně malý, je konzistentní s předchozími výzkumy,

které ukazují, že i mírné rozdíly v pozornosti mohou mít kumulativní dopady na rozhodování o nákupu, zejména v prostředí reálné spotřeby.

Ačkoliv vysvětlená variabilita modelu ($R^2_{McF} = 0.0116$) zůstává relativně nízká, což je u predikce binárního rozhodnutí běžné, výsledky přesto **podporují hypotézu H3**. Doba vizuální pozornosti se ukazuje jako relevantní prediktor, který může hrát roli v nákupním rozhodování – čím déle reklama udrží pozornost zákazníka, tím vyšší je šance, že dojde k nákupu.



Graf 4 – Vztah mezi dobou zaujetí a pravděpodobností nákupu (H3)

2.3.4. Vliv hyper-personalizace na obecné nákupní chování (H4)

Měřítka vhodnosti modelů

Model	Odchylka	AIC	R ² _{McF}
1 (bez mediátoru)	5623	5627	2.78e-6
2 (s mediátorem)	5558	5564	0.0117

Poznámka. Modely jsou vypočtené na základě vzorku o N=4810

Tabulka 7 – Míry vhodnosti regresních modelů pro predikci pravděpodobnosti nákupu (H4a, H4b)

Modelové koeficienty - Nákup jakéhokoliv produktu

Prediktor	Odhad	SE	Z	p	Poměr šancí (OR)
Model 1 (bez mediátoru)					
Intercept	0.98391	0.0460	21.385	<.001	2.67
Podmínka:					
G – HP	0.00810	0.0649	0.125	0.901	1.01
Model 2 (s mediátorem)					
Intercept	0.7486	0.05462	13.705	<.001	2.11
Podmínka:					
G – HP	0.0299	0.06529	0.458	0.647	1.03
Doba zaujetí	0.0204	0.00280	7.303	<.001	1.02

Poznámka. Odhady představují logaritmičké pravděpodobnosti "Nákup jakéhokoliv produktu = 1" vs. "Nákup jakéhokoliv produktu = 0"

Tabulka 8 – Regresní koeficienty pro modely testující vlivy HP na pravděpodobnost nákupu (H4a, H4b)

Za účelem ověření hypotézy H4b byla provedena binomická logistická regrese, která testovala, zda vztah mezi typem reklamní podmínky (hyper-personalizovaná vs. generická) a pravděpodobností nákupu jakéhokoliv produktu je částečně zprostředkován délkou zaujetí reklamou.

První model (H4a) testující pouze přímý vliv reklamní podmínky ukázal, že efekt hyper-personalizované reklamy na pravděpodobnost nákupu nebyl statisticky významný ($p = .901$). Po přidání mediátoru ve formě doby zaujetí do rozšířeného modelu se přímý efekt reklamní podmínky nezměnil a zůstal nevýznamný ($B = 0.030$, $p = .647$). Naproti tomu doba zaujetí

vykazovala silný a statisticky významný pozitivní vztah k pravděpodobnosti nákupu ($B = 0.020$, $SE = 0.0028$, $Z = 7.303$, $p < .001$, $OR = 1.02$).

Navzdory absence přímého efektu experimentální podmínky (G / HP) v analyzovaných modelech, přítomnost statisticky významného mediátoru a zároveň mírné zvýšení vysvětlené variance (R^2_{McF} z 2.78×10^{-6} na 0.0117) indikují, že doba zaujetí může představovat částečný mechanismus, skrze který hyper-personalizovaná reklama působí na nákupní rozhodování.

Tento závěr je podpořen i samostatnou analýzou v rámci hypotézy H3, která prokázala, že delší pozornost věnovaná reklamnímu sdělení (měřená jako doba zaujetí) obecně zvyšuje pravděpodobnost nákupu bez ohledu na typ reklamy. I přes částečné potvrzení **hypotézy H4b**, nemůže být **hypotéza H4** plně potvrzena jako celek, kvůli absence statisticky signifikantního efektu hyper-personalizované reklamy na obecnou pravděpodobností nákupu, kterým byla podmíněna **hypotéza H4a**.

2.3.5. Moderující efekty demografie (VO1)

2.3.5.1. Vliv věku a pohlaví na dobu zaujetí

ANOVA - Doba zaujetí

	Sum of Squares	df	Mean Square	F	p	η^2
Celkový model	9541	7	1363	5.97	<.001	
Věk	8136	6	1356	5.80	<.001	0.007
Pohlaví	1405	1	1405	6.01	0.014	0.001
Residuals	1.12e+6	4802	234			

Tabulka 9 – Výsledky analýzy rozptylu (ANOVA) pro dobu zaujetí podle věku a pohlaví (VO1a)

Post Hoc srovnání - Pohlaví

Porovnání		Průměrný rozdíl	SE	df	t	Ptukey	Cohenova d
Pohlaví	Pohlaví						
F	- M	-1.98	0.808	4802	-2.45	0.014	-0.130

Poznámka. Srovnání jsou založena na odhadovaných mezních průměrech


Tabulka 10 – Post hoc test rozdílů v době zaujetí zákazníka mezi pohlavími (VO1a)

Za účelem ověření výzkumné otázky VO1a byla provedena dvoufaktorová analýza rozptylu (ANOVA) s věkem (7 kategorií) a pohlavím (2 kategorie) jako mezi-subjektovými faktory. Výsledky ukázaly statisticky významný hlavní efekt věku, $F(6, 4802) = 5.80, p < .001, \eta^2 = .007$, a pohlaví, $F(1, 4802) = 6.01, p = .014, \eta^2 = .001$. Přestože velikosti efektu jsou malé, výsledek naznačuje, že demografické charakteristiky mohou hrát roli v reakci zákazníka na sdělení.

Post hoc test pro pohlaví ukázal, že muži setrvaly u reklamy o 1,98 sekundy déle než ženy $t(4802) = -2.45, p = .014$, což odpovídá malému efektu (Cohenovo $d = -0.13$). V post hoc testu pro věkové kategorie (viz. příloha č. 2) se nejdelší doba zaujetí vyskytovala u

respondentů ve věku 40–59 let, zatímco výrazně kratší dobu pozornosti vykazovaly skupiny 10s, 20s a 70s. Největší průměrný rozdíl o velikosti 4,23 sekundy byl zaznamenán mezi 20s a 40s ($p < .001$, Cohenovo $d = -0.28$), a 2,70 sekundy mezi 30s a 40s ($p < .001$, Cohenovo $d = -0.18$). Tyto výsledky potvrzují, že věkové rozdíly v pozornosti jsou nejvýraznější mezi mladšími a středními věkovými skupinami.

Doplňující výsledky ANOVA analýz ukazují, že změřený vliv demografických proměnných na dobu zaujetí závisí na typu reklamy (G / HP). V generické podmínce byl významným prediktorem věk ($p < .001$), zatímco pohlaví nikoli. V hyper-personalizované reklamě se tento vztah otočil – věk nevykazoval statisticky významný vliv ($p = .106$), ale pohlaví ano ($p = .015$). V souhrnném modelu byly oba faktory významné, i když s malým efektem. Tyto výsledky naznačují, že hyper-personalizovaná reklama může snižovat věkové rozdíly v reakci na obsah, zatímco u generické reklamy se věkové skupiny liší více. Pohlaví hraje roli spíše při personalizovaném obsahu.



Graf 5 – Odhadované mezní průměry doby zaujetí podle věku a pohlaví ve dvou experimentálních podmínkách G vs. HP (VO1a)

2.3.5.2. Vliv věku na obecné nákupní chování

Měřítka vhodnosti modelu a omnibus test významnosti prediktorů

Model/Prediktor	Odchylka	AIC	R ² _{McF}	Celkový test modelu		
				χ ²	df	p
Model	5530	5556	0.0166	93.3	12	<.001
Podmínka	-	-	-	0.00252	1	0.960
Věk	-	-	-	51.01203	6	<.001
Podmínka * Věk	-	-	-	4.51106	5	0.478

Poznámka. Modely vypočtené na základě vzorku o velikosti N=4810

Tabulka 11 – Metriky logistického regresního modelu a omnibus test významnosti prediktorů ve vztahu k nákupu (VO1b)

Pro ověření vlivu věku, typu reklamního stimulu (G / HP) a jejich interakce na obecné nákupní chování byl sestaven model binární logistické regrese. Kvalita celkového modelu byla ověřena pomocí testu věrohodnostního poměru, který ukázal statisticky významný výsledek ($\chi^2(12) = 93.30, p < .001$). To znamená, že model zahrnující věk, experimentální podmínku a jejich interakci poskytuje výrazně lepší vysvětlení dat ve srovnání s nulovým modelem. I přes statistickou signifikanci tento model vykazoval velmi nízkou míru vysvětleného rozptylu ($R^2_{mCF} = 0.017$).

Výsledky binární logistické regrese pro jednotlivé prediktory ukázaly, že věk zákazníka má statisticky významný vliv na pravděpodobnost nákupu ($\chi^2(6) = 51,01; p < .001$), a to nezávisle na typu reklamy. Jako referenční kategorie byla použita skupina 30–39 let. Zákazníci ve věku 50–59 let vykazovali přibližně třikrát vyšší pravděpodobnost nákupu ($OR = 2,97; p < .001$), a skupina 60–69 let vykazovala více než dvojnásobnou pravděpodobnost nákupu ($OR = 2,44; p < .001$), ve srovnání s referenční kategorií. Efekt byl na hranici statistické významnosti také u skupiny 40–49 let ($OR = 1,28; p = .077$). Skupiny 10–19 let a 70+ nebyly dále interpretovány vzhledem k extrémně nízkému počtu případů (viz. příloha č. 1).

Ačkoli mezi věkem a pravděpodobností nákupu existuje spojitost, interakce mezi věkem a experimentální podmínkou (hyper-personalizace vs. generická reklama) nebyla statisticky významná ($\chi^2(5) = 4,51; p = .478$), což naznačuje, že vliv věku na nákupní chování zůstává obdobný napříč oběma podmínkami.

2.3.5.3. Vliv pohlaví na obecné nákupní chování

χ^2 Test

Podmínka		Hodnota	df	p	Cramerovo V
HP	χ^2	0.710	1	0.400	0.0173
	N	2385			
G	χ^2	24.335	1	<.001	0.1002
	N	2425			
Celkem	χ^2	15.781	1	<.001	0.0573
	N	4810			

Tabulka 12 – Chí-kvadrát test nezávislosti mezi pohlavím a nákupním chováním (VO1b)

Na základě kontingenční tabulky (viz. příloha č. 3) a výsledků chí-kvadrát testu lze již před post hoc analýzou pozorovat celkový trend v nákupním chování podle pohlaví. Z celkového souboru ($N = 4810$) vyplývá, že muži nakupovali častěji, než bylo očekáváno na základě jejich populačního zastoupení (9,2 % vs. očekávaných 8,3 %), zatímco ženy nakupovaly méně (90,8 % vs. očekávaných 91,7 %). Tento rozdíl byl sice statisticky významný χ^2 (1, $N = 4810$) = 15.78, $p < .001$, ale jeho efekt byl velmi malý (Cramerovo $V = .0573$). Tento výchozí rámec dále rozlišujeme podle experimentální podmínky.

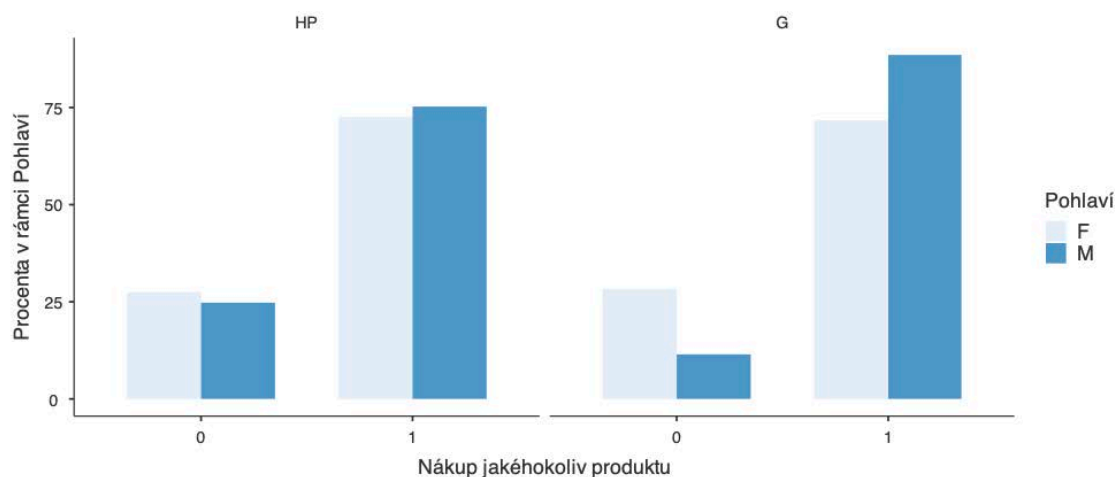
Post Hoc Test

Podmínka	Nákup jakéhokoliv produktu	Rezidua	Pohlaví	
			F	M
HP	0	Nestandardizovaná	5.23	-5.23
		Standardizovaná	0.842	-0.842
	1	Nestandardizovaná	-5.23	5.23
		Standardizovaná	-0.842	0.842
G	0	Nestandardizovaná	28.50	-28.50
		Standardizovaná	4.933	-4.933
	1	Nestandardizovaná	-28.50	28.50
		Standardizovaná	-4.933	4.933

Tabulka 13 – Post hoc analýza rozdílů v nákupním chování podle pohlaví a experimentální podmínky (VO1b)

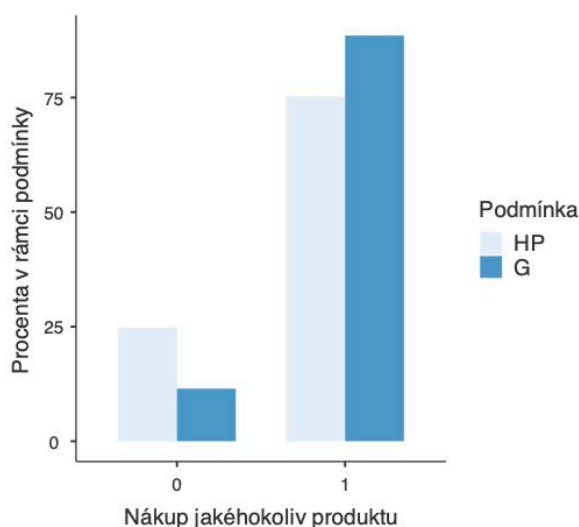
Post hoc analýza rozdílů v nákupním chování podle pohlaví a typu reklamy ukázala zajímavý kontrast mezi podmínkami. V experimentální podmínce generické reklamy (G) byl rozdíl mezi muži a ženami statisticky významný, kdy muži nakupovali výrazně častěji, než by odpovídalo očekávané frekvenci ($z = 4.933$), zatímco ženy méně ($z = -4.933$), kdy $|z| > 1.96$ vyjadřuje signifikantní rozdíl dle na naší předem nastavené úrovně $p < .05$.

Naproti tomu v podmínce hyper-personalizované reklamy (HP) rozdíl mezi pohlavími sice existoval, ale jeho intenzita byla výrazně nižší ($z = \pm 0.842$) a nedosáhla statisticky signifikantní hladiny. Vizualizace z Grafu 6 potvrzuje, že míra nákupu u žen i mužů byla v této podmínce podobná (ženy: ~72 %, muži: ~75 %).



Graf 6 – Procentuální zastoupení nákupního chování podle pohlaví mezi G a HP podmínkou (VO1b)

Zajímavé zjištění přinesla právě izolace mužů při analýze, které ukázalo, že míra nákupu mezi muži klesla v podmínce hyper-personalizované reklamy o přibližně 13,3 % bodu ve srovnání s generickou reklamou (viz. přílohy č. 4 a 5). To se může vysvětlovat jiným např. moc citlivým zaměřením reklam na ustupující vlasy. Zajímavé zjištění přinesla analýza izolující výhradně muže, která ukázala, že pravděpodobnost nákupu v podmínce hyper-personalizované reklamy klesla přibližně o 13,3 % ve srovnání s podmínkou generické reklamy. Tento pokles může naznačovat, že personalizovaný obsah byl pro tuto skupinu zaměřen na citlivé téma ustupujících vlasů (viz. kap. Diskuze a shrnutí).



Graf 7 – Srovnání nákupního chování mužů podle typu podmínky G vs. HP (VO1b)

2.4. Diskuse a shrnutí

Cílem tohoto výzkumu bylo nejprve navrhnout a popsat architekturu systému pro dynamickou hyper-personalizaci reklamního sdělení ve fyzickém obchodě a následně skrze jeho implementaci prověřit efekty hyper-personalizované reklamy v reálném prostředí off-line retailu. Výsledky tohoto výzkumu tak představují přínos nejen praktický, kdy popisují a demonstrují aplikaci nových technologií umělé inteligence do marketingové praxe, ale také akademický, kdy pomohli vyplnit výzkumnou mezeru v efektivitě a dopadech personalizované komunikace ve kontextu fyzického prostředí.

Experiment vedený ve čtyřech kamenných prodejnách za reálného provozu demonstroval signifikantní vliv personalizované komunikace na zákaznické chování ve fyzickém prostředí. Hyper-personalizovaná reklama dokázala upoutat pozornost zákazníků o něco déle než reklama generická, čímž potvrdila hypotézu H1. Tento naměřený nárůst v pozornosti nebyl sice z pohledu velikosti efektu velký (Cohenovo $d \approx 0,09$), ale v reálném prostředí může mít i minimální prodloužení pozornosti dopad na povědomí o značce, nebo může vést ke změně zákaznických preferencí (Havas Media Network et al., 2024). V souladu s daty o personalizaci v on-line prostředí lze potvrdit, že hyper-personalizace zvyšuje zájem a zapojení zákazníků. Z akademického hlediska jde o důležitý důkaz přenositelnosti konceptu personalizace z on-line do off-line prostředí. Zatímco řada studií v digitálním marketingu ukázala, že dynamická personalizace zvyšuje zapojení uživatelů, výsledky této studie podobný efekt poprvé kvantifikují přímo v prostředí kamenném obchodě. Právě překlenutí této výzkumné propasti digitálního a fyzického prostředí lze považovat za jeden z inovativních přínosů práce.

Práce dala do kontrastu tyto dva světy taky při srovnání dopadu na reálné nákupní chování zákazníků, kdy se výzkumná hypotéza H2 neukázala jako validní. Statistická nerelevance zvýšení pravděpodobnosti nákupu ve fyzickém prostředí je v kontrastu s poznatky z prostředí on-line reklamy, ve kterém personalizace prokazatelně vede právě ke konverzi (Grbovic et al., 2015; S. Matz et al., 2017). Některé z možných příčin nesignifikance tohoto

efektu můžou být například velmi nízká míra nákupu konkrétního produktu po jedné reklamní interakci, nedostatečnost jednorázové expozice zákazníka či velice specifické zaměření prodejny a demografické homogenity zákazníků (diskutováno v kap. Limity práce a doporučení pro další výzkum). Z praktického hlediska tento výsledek signalizuje, že přínos hyper-personalizace se nemusí projevit přímo ve formě okamžitých prodejů konkrétních položek, alespoň ne při první interakci.

Za významný nálezn lze považovat potvrzení vztahu mezi zaujetím či pozorností vůči reklamnímu nosiči a nákupním chováním (H3). Tento výsledek potvrzuje tradiční reklamní modely jako AIDA, které vnímají dostatečnou pozornost jako nutnou podmínku pro konverzi. V rámci experimentu byl kvantifikován vztah mezi pozorností a nákupem nárůstem pravděpodobnosti nákupu o 2 % každou dodatečnou sekundou vizuální pozornosti zákazníka. Výsledky tohoto výzkumu odpovídají i výše zmíněným aktuálním studiím z praxe, které potvrzují silnou korelaci a provázání těchto dvou proměnných (Basset & Rooney, 2024; Havas Media Network et al., 2024), a přinášejí empirický důkaz o relevanci ekonomiky pozornosti nejen v digitálním světě, ale i ve fyzickém kontextu. Právě chápání pozornosti nejen uživatelů, ale i zákazníků jako omezeného cenného zdroje (Williams, 2018) může vést k efektivnějším komunikačním strategiím jak v digitálním, tak fyzickém prostředí.

Kromě zkoumaných vztahů mezi hlavními proměnnými přinesla tato studie i poznatky o vlivu demografických profilů zákazníka na nákup a pozornost. Statistické analýzy ukázaly měřitelné rozdíly mezi experimentálními podmínkami hyper-personalizované a generické reklamy. Například u generické podmínky existovaly v rámci demografie výrazné rozdíly v délce zaujetí mezi věkovými skupinami, zatímco v případě hyper-personalizované reklamy se projevily statisticky významné rozdíly pouze mezi pohlavím, kdy ženy v průměru věnovaly personalizované reklamě delší pozornost než muži.

Zajímavý efekt se objevil při analýze vlivu pohlaví na nákupní chování, kdy jsme u mužů mohli pozorovat statisticky významný pokles nákupu při zapojení hyper-personalizované experimentální podmínky. Jedno z možných vysvětlení tohoto jevu se váže k zmíněné studii od Priyadharshini & Mathewa (2016), která v on-line prostředí popisuje pokles interakcí i

konverzního poměru při personalizovaných reklamách na choulostivé produkty. To se u tohoto experimentu promítalo skrze produktovou nabídku, která byla pro muže určená, a nastavením inferenční vrstvy promptu. Nejvýraznější negativní efekt na nákupní chování jsme naměřili u reklam na *Aktivační vlasové sérum*, které bylo druhou nejdoporučovanější položkou pro mužského zákazníka (doporučena ve 120 interakcích). Díky přednastavené logice promptu generovalo LLM texty s důrazem na komunikaci zákaznické potřeby v kombinaci s produktovou hodnotou. To v případě zákazníků s řídnoucími vlasy vedlo k hyper-personalizovaným textům jako například:

Generované reklamní texty pro *Aktivační vlasové sérum*

Session ID	Text
539	Ztráta vlasů? Podpořte jejich růst s naším aktivním sérem! Přirozená inovace pro zdravou pokožku hlavy.
975	Podpořte růst vlasů s naším přírodním sérem! Získejte až 28.200 nových vlasů a zdravou pokožku hlavy.
6215	Získejte zdravé vlasy a obnovte jejich objem s účinným sérem! Obsahuje přírodní ingredience pro růst vlasů.

Tabulka 14 – Příklad vygenerovaných reklamních textů pro *Aktivační vlasové sérum*

Právě tato explicitnější narážka na pro některé zákazníky choulostivou potřebu mohla vést ke snížené tendenci nákupu a interakce v obchodě. Vliv sociálního tlaku, řízení dojmu a veřejné sebepojetí na zákaznické chování popisuje také Hess a spol. (2020). Ti upozorňují, že lidé mají tendenci vnímat své veřejné vystupování a snaží se kontrolovat, jakým způsobem jsou ostatními vnímáni. Personalizované reklamy zobrazované na veřejnosti, které odkazují na citlivé aspekty sebevnímání, mohou tento proces ovlivnit a vyvolat u zákazníků obavy o to, jaký dojem vytváří (Fenigstein et al., 1975).

Přínos práce lze shrnout jak v akademické, tak praktické rovině. Z akademického hlediska studie vyplňuje mezeru ve výzkumu off-line hyper-personalizace kdy jako jedna z prvních empiricky testuje systém personalizované digitální reklamy přímo na prodejní ploše a kvantifikuje jeho dopad na pozornost a prodeje. Z metodologického pohledu je práce jedinečná ve svém propojení dat o pozornosti zákazníků sesbíraných skrze nástroje počítačového vidění s reálnými transakčními daty. Z praktického hlediska tato studie

ukazuje možné použití nových technologií umělé inteligence jako LLM pro škálování dynamické hyper-personalizace v prodejním prostředí.

2.5. Limity práce a doporučení pro další výzkum

Jako většina empirických výzkumů i tento má ve svém poznání limity a omezení, které jsou potřeba reflektovat a využít je k návrhu možných směrů budoucích prací na toto téma. Prvním výrazným omezením oproti personalizačním praktikám v digitální reklamě je nemožnost individuálního rozeznávání zákazníků, která by umožnila sledovat a vyhodnocovat jeho historická behaviorální data. Navržený systém z důvodu právních limitací nezaznamenává identitu ani opakované návštěvy zákazníka a každá interakce tak byla posuzována izolovaně.

Další vnímanou limitací pro generalizaci výsledků je složení zákaznické základny sledovaných obchodů, ve kterých tento experiment probíhal. Z deskriptivní analýzy dat vyšla najevo výrazná převaha ženského pohlaví v demografickém schématu (91 %) oproti mužskému zastoupení (9 %). Homogenita typického zákaznického profilu se ukázala také na věkovém rozložení, kdy zákazníci ve věku kolem 30 let tvořili 63 % celkového výzkumného souboru. Dopad na změřené efekty mohl mít i velice úzce zaměřený výběr produktů, který se skládá výhradně z kosmetiky a nemusel být pro viditelnější personalizaci dostatečně různorodý. Je možné, že v kontextu prodejen s větší produktovou diverzitou jako např. supermarket, obchod s elektronikou či drogerie by zákazníci mohli na personalizovanou reklamu reagovat jinak. Tento limit lze připodobnit k rozdílu mezi velkými e-shopy jako Amazon, které nabízejí široké spektrum produktů od elektroniky přes knihy až po domácí potřeby, a specializovanými e-shopy zaměřenými například pouze na prodej outdoorového vybavení. Zatímco na Amazonu umožňuje vysoká diverzita sortimentu cílit reklamu na velmi odlišné potřeby zákazníků, v úzce specializovaném e-shopu by i personalizované sdělení často oslovovalo zákazníky s velmi podobnými motivacemi, což snižuje prostor pro výraznější efekt personalizace na zákaznické chování.

Možný limit se vyskytl také v cloudovém řešení inferenční a generativní vrstvy, který byl nastíněn v kapitole o předzpracování dat, kdy včasnost doručení personalizované reklamy závisela na výkonnosti internetového připojení prodejny. Právě ta se mezi různými lokacemi výrazně lišila. Zatímco ve dvou obchodech se čas odezvy LLM modulu pohyboval kolem 4 sekundy, ve zbývajících dvou obchodech se držel v rozmezí 6 až 8 sekund. Právě výraznější odchylka od dynamické hyper-personalizace v reálném čase by mohla mít dopad na změřenou efektivitu reklamních sdělení. Nutné je zmínit i výše popsany kompromis při tvorbě časového okna definující nákup po vystavení reklamním stimulem. I přesto, že se při tvorbě proměnné vycházelo z dat intervalů mezi nákupy, nelze s naprostou jistotou očekávat, že všechny nákupy byly správně přiřazené k jednotlivým interakcím. Nicméně pro potřeby tohoto experimentu byla tato metoda praktické operacionalizace nákupní reakce na reklamu v prostředí prodejny vyhodnocena jako dostačující.

Nakonec je vhodné zmínit i limitace dané samotnou povahou terénního experimentu. A ačkoli jak v rámci experimentálního designu, tak i v post procesování dat byly provedeny kroky k maximalizaci interní validity (např. randomizace, kontroly podmínek, nebo čištění dat od extrémů) v reálném obchodě nelze vyloučit vliv dalších rušivých proměnných. Ty mohou přijít ve formě momentální vytíženost prodejny, či chování obsluhujícího personálu, což může mírně ovlivnit nákupní chování u zákazníků nezávisle na reklamě samotné. Tyto vlivy jsme nemohli plně kontrolovat, což vnáší do dat určitý šum. Celkově je však třeba zdůraznit, že uvedené limity jsou u terénních studií obvyklé a neznehodnocují závěry, spíše vytyčují prostor pro opatrnost v interpretaci a náměty pro další zlepšení experimentálního designu.

Na základě těchto identifikovaných limitací se nabízí několik doporučení pro budoucí výzkum v tomto odvětví. Jako jedna z hlavních cest k rozšíření experimentálního záběru může být testování systému v různých typech obchodů a prodejních segmentů, což by pomohlo ověřit obecnou platnost pozorovaných efektů. Například implementace systému dynamické hyper-personalizované reklamy v supermarketu, kde zákazníci nakupují rychloobrátkové zboží denní potřeby, může přinést odlišné výsledky než v případě s dárkovým sortimentem. Toto zapojení odlišných segmentů by zároveň vedlo i k možnosti testování personalizace na případech heterogenní nabídky produktů, kde by se její efekt mohl lišit například u levných nákupů impulzivnější povahy oproti těm dražším.

Dalším směrem může být rozšíření schopností inferenčního systému skrze zapojení nových personalizačních parametrů a metod. Budoucí systémy by mohly využívat nejen data z vizuální analýzy, ale také kontextuální údaje jako čas dne, zaplněnost obchodu, sezónnost, či probíhající akce. Zajímavou cestou se jeví i využití strojového učení k adaptivnímu zlepšování modelů na základě sbíraných dat v prodejně. Systémy by tak na základě učení s učitelem a zpětnovazebného učení dokázaly, podobně jako systémy v on-line prostředí, časem zlepšovat a optimalizovat jejich schopnost personalizace. Při rozšíření možností hyper-personalizace však nelze opomenout i narůstající potřebu etického rámce a ochrany soukromí zákazníků. Budoucí výzkum by proto měl nejen technicky zdokonalovat systémy personalizace, ale paralelně také zkoumat, jaké formy a míra personalizace jsou z pohledu zákazníků přijatelné a jak tyto faktory ovlivňují efektivitu sdělení.

V konečném důsledku tak může správně uchopený budoucí výzkum vést jak k rozvoji teoretických modelů personalizace v prostředí kamenných prodejen, tak i k nastavení praktických příkladů propojení digitální personalizace a tradičního nákupního procesu pro spokojenost obchodníků i zákazníků.

Závěr

Předmětem a cílem této diplomové práce bylo navržení, zapojení a ověření nových nástrojů umělé inteligence do personalizace marketingové komunikace. V rámci teoretické části byla zpracována rozsáhlá literární rešerše, která propojila technologické a psychologické aspekty marketingové personalizace a položila tak základ pro návrh architektury vlastního hyper-personalizačního systému.

Hlavním přínosem praktické části práce je úspěšný návrh a implementace dynamického hyper-personalizovaného reklamního systému, který byl pilotně nasazen a testován ve čtyřech kamenných kosmetických prodejnách. Tento systém v reálném provozu generoval a zobrazoval zákazníkům personalizované reklamní sdělení na základě jejich vizuálních charakteristik a chování. Experimentální nasazení systému poskytlo unikátní možnost empirického ověření účinnosti personalizace v prostředí fyzického obchodu.

Analýza nasbíraných dat odhalila měřitelný vliv hyper-personalizovaných sdělení na chování zákazníků. Ve srovnání s generickou experimentální podmínkou došlo k signifikantnímu prodloužení průměrné doby pozornosti věnované zákazníkem reklamě. Tento nárůst pozornosti se ale nepromítl do pozorovaného nákupního rozhodování zákazníků, které nevykázalo statisticky signifikantní změnu mezi generickou a hyper-personalizovanou reklamou. Zajímavé výsledky přinesla i analýza vztahu mezi mírou zaujetí a pravděpodobností nákupu a analýza rozdílů v účinku personalizace podle demografických charakteristik, které obě odhalily statisticky významné efekty.

Získané poznatky jsou významným příspěvkem jak pro marketingovou teorii, tak pro praxi. Práce poskytuje empirické ověření účinků hyper-personalizace v retailu, čímž podkládá dosavadní převážně teoretickou diskusi daty z reálného prostředí. Zároveň byl v rámci práce vyvinut a otestován inovativní systém pro dynamickou hyper-personalizaci, který může sloužit jako vzor aplikace generativní umělé inteligence do marketingového mixu pro marketingové experty a maloobchodníky. Z hlediska akademického výzkumu výsledky dávají prostor pro navazující studie zkoumající například efekt hyper-personalizace v odlišných prodejních segmentech či možnosti zlepšení navržené systémové architektury o schopnost dynamické optimalizace personalizační logiky.

Summary

The subject and objective of this thesis was the design, integration, and evaluation of new artificial intelligence tools in the personalization of marketing communication. In the theoretical part, an extensive literature review was conducted, linking technological and psychological aspects of marketing personalization, thus laying the foundation for the design of a custom hyper-personalization system architecture.

The main contribution of the practical part is the successful design and implementation of a dynamic hyper-personalized advertising system, which was pilot-tested in four brick-and-mortar cosmetic stores. In real operating conditions, this system generated and displayed personalized advertising messages to customers based on their visual characteristics and behavior. The experimental deployment of the system provided a unique opportunity for empirical validation of the effectiveness of personalization in a physical retail environment.

The analysis of the collected data revealed a measurable impact of hyper-personalized messages on customer behavior. Compared to the generic experimental condition, there was a significant increase in the average attention time customers dedicated to the advertising content. However, this increase in attention did not translate into statistically significant changes in observed purchase decisions between the generic and hyper-personalized advertising conditions. Interesting results also emerged from the analysis of the relationship between attention duration and purchase probability, as well as from the analysis of differences in the effects of personalization across demographic groups, both of which revealed statistically significant effects.

The findings represent a significant contribution to both marketing theory and practice. The thesis provides empirical evidence on the effects of hyper-personalization in retail, thus complementing the previously predominantly theoretical discussion with real-world data. Furthermore, an innovative system for dynamic hyper-personalization was developed and tested, which can serve as a model for the application of generative artificial intelligence within the marketing mix for marketing experts and retailers. From an academic research perspective, the results open up space for follow-up studies, for example, investigating the effects of hyper-personalization in different retail segments or exploring opportunities to enhance the proposed system architecture with dynamic optimization of personalization logic.

Použitá literatura

- Acquisti, A. (2004). Privacy in electronic commerce and the economics of immediate gratification. *Proceedings of the 5th ACM Conference on Electronic Commerce*, 21–29. <https://doi.org/10.1145/988772.988777>
- Acquisti, A., & Grossklags, J. (2005). Privacy and rationality in individual decision making. *IEEE security & privacy*, 3(1), 26–33.
- Acquisti, A., John, L. K., & Loewenstein, G. (2012). The Impact of Relative Standards on the Propensity to Disclose. *Journal of Marketing Research*, 49(2), 160–174. <https://doi.org/10.1509/jmr.09.0215>
- Aguirre, E., Mahr, D., Grewal, D., de Ruyter, K., & Wetzels, M. (2015). Unraveling the Personalization Paradox: The Effect of Information Collection and Trust-Building Strategies on Online Advertisement Effectiveness. *Journal of Retailing*, 91(1), 34–49. <https://doi.org/10.1016/j.jretai.2014.09.005>
- AI at Meta. (2020). *Yann LeCun on the future of deep learning hardware* [Video recording]. <https://www.youtube.com/watch?v=9r2lqrtQXFQ>
- Andriulo, F. C., Fiore, M., Mongiello, M., Traversa, E., & Zizzo, V. (2024). Edge computing and cloud computing for internet of things: A review. *Informatics*, 11(4), 71. <https://www.mdpi.com/2227-9709/11/4/71>
- AP News. 2025 *Judge allows newspaper copyright lawsuit against OpenAI to proceed*. AP News. <https://apnews.com/article/nyt-openai-copyright-lawsuit-chatgpt-cc19ef2cf3f23343738e892b60d6d7a6>
- Ariker, M., Heller, J., Diaz, A., & Perrey, J. (2015). How marketers can personalize at scale. *Harvard Business Review*, 23.
- Arora, N., Dreze, X., Ghose, A., Hess, J. D., Iyengar, R., Jing, B., Joshi, Y., Kumar, V., Lurie, N., Neslin, S., Sajeesh, S., Su, M., Syam, N., Thomas, J., & Zhang, Z. J. (2008). Putting one-to-one marketing to work: Personalization, customization, and choice. *Marketing Letters*, 19(3), 305. <https://doi.org/10.1007/s11002-008-9056-z>
- Arora, N., Ensslen, D., Fiedler, L., Liu, W. W., Robinson, K., Stein, E., & Schüler, G. (2021, 11). *The value of getting personalization right—Or wrong—Is multiplying*. McKinsey & Company. <https://www.mckinsey.com/business-functions/marketing-and-sales/our-insights/the-value-of-getting-personalization-right-or-wrong-is-multiplying>
- Arthur, C. 2013 Tech giants may be huge, but nothing matches big data. *The Guardian*. <https://www.theguardian.com/technology/2013/aug/23/tech-giants-data>
- Basset, D., & Rooney, R. 2024 *Maximising Profit Through Attention*. Ebiquity & Lumen Research. <https://www4.ebiquity.com/EbiquityXLumen-Maximising-Profit-through-Attention-Oct-31-2024-2.pdf>

- Becker, G. S. (1976). *The economic approach to human behavior* (Roč. 803). University of Chicago press.
- Bennett, J., Lanning, S., & Netflix, N. (2007). The Netflix Prize. *In KDD Cup and Workshop in conjunction with KDD*.
- Bleier, A., De Keyser, A., & Verleye, K. (2018). Customer Engagement Through Personalization and Customization. In R. W. Palmatier, V. Kumar, & C. M. Harmeling (Ed.), *Customer Engagement Marketing* (s. 75–94). Springer International Publishing. https://doi.org/10.1007/978-3-319-61985-9_4
- Boerman, S. C., Kruikemeier, S., & Zuiderveen Borgesius, F. J. (2017). Online Behavioral Advertising: A Literature Review and Research Agenda. *Journal of Advertising*, 46(3), 363–376. <https://doi.org/10.1080/00913367.2017.1339368>
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., & Askell, A. (2020). Language models are few-shot learners. *Advances in neural information processing systems*, 33, 1877–1901.
- Carrascal, J. P., Riederer, C., Erramilli, V., Cherubini, M., & De Oliveira, R. (2013). Your browsing behavior for a big mac: Economics of personal information online. *Proceedings of the 22nd International Conference on World Wide Web*, 189–200. <https://doi.org/10.1145/2488388.2488406>
- Cohen, J. (2013). *Statistical power analysis for the behavioral sciences*. routledge. <https://www.taylorfrancis.com/books/mono/10.4324/9780203771587/statistical-power-analysis-behavioral-sciences-jacob-cohen>
- Concordia (Ředitel). září *The Power of Big Data and Psychographics | 2016 Concordia Annual Summit* [YouTube Video]. <https://www.youtube.com/watch?v=n8Dd5aVXLCc>
- Costa, P. T., & McCrae, R. R. (1992). Normal personality assessment in clinical practice: The NEO Personality Inventory. *Psychological Assessment*, 4(1), 5–13. <https://doi.org/10.1037/1040-3590.4.1.5>
- Cramér, H. (1999). *Mathematical methods of statistics* (Roč. 9). Princeton university press. <https://www.google.com/books?hl=cs&lr=&id=jV2YDwAAQBAJ&oi=fnd&pg=PA3&dq=Cram%C3%A9r,+Harald.+1946.+Mathematical+Methods+of+Statistics.+Princeton:+Princeton+University+Press,+page+282&ots=OZuVC9LtAf&sig=3iPwagUVsCUCd5gP00SRHPYKn48>
- Dang, M. (2024). *Právní aspekty generativní umělé inteligence*. <https://dspace.cuni.cz/handle/20.500.11956/196009>
- Dangi, H., & Malik, A. (2017). Personalisation in marketing: An exploratory study. *International Journal of Internet Marketing and Advertising*, 11(2), 124. <https://doi.org/10.1504/IJIMA.2017.084079>

- Davenport, T. H. (2023). Hyper-Personalization for Customer Engagement with Artificial Intelligence. *Management and Business Review*, 3(1–2), 29–36. <https://doi.org/10.1177/2694105820230301006>
- Ducoffe, R. H. (1996). Advertising value and advertising on the web. *Journal of advertising research*, 36(5), 21–21.
- E2Analyst. 2023 GPT-4: Everything you want to know about OpenAI's new AI model. *Predict*. <https://medium.com/predict/gpt-4-everything-you-want-to-know-about-openais-new-ai-model-a5977b42e495>
- Evropský parlament. (2024). *Nářízení Evropského parlamentu a Rady (EU) 2024/1689*. <https://eur-lex.europa.eu/eli/reg/2024/1689/oj/eng>
- Eysenck, M. W., & Keane, M. T. (2008). *Kognitivní psychologie*. Academia Praha. https://www.researchgate.net/profile/Mark-Keane-2/publication/47041539_Kognitivni_psychologie/links/09e4150a4d1ef0c66300000/Kognitivni-psychologie.pdf
- Fan, H., & Poole, M. S. (2006). What Is Personalization? Perspectives on the Design and Implementation of Personalization in Information Systems. *Journal of Organizational Computing and Electronic Commerce*, 16(3–4), 179–202. <https://doi.org/10.1080/10919392.2006.9681199>
- Faraone, M. F., Gorgoglione, M., & Palmisano, C. (2010). Contextual segmentation: Using context to improve behavior predictive models in e-commerce. *2010 IEEE International Conference on Data Mining Workshops*, 1053–1060. <https://ieeexplore.ieee.org/abstract/document/5693411/>
- Farruh, K. (2020). Consumer life cycle and profiling: A data mining perspective. *Consumer Behavior and Marketing*, 1.
- Fenigstein, A., Scheier, M. F., & Buss, A. H. (1975). Public and private self-consciousness: Assessment and theory. *Journal of consulting and clinical psychology*, 43(4), 522.
- Fitzsimons, G. M., Chartrand, T. L., & Fitzsimons, G. J. (2008). Automatic effects of brand exposure on motivated behavior: How apple makes you “think different”. *Journal of consumer research*, 35(1), 21–35.
- Fulton, M. A. 2021 *To click or not to click?: An experimental study into the effects of personalization, marketing channel, and product type on consumers' attitudes, perceived relevance, and click through intentions towards online advertisements*. [Info:eu-repo/semantics/masterThesis]. University of Twente. <http://essay.utwente.nl/85998/>
- Goli, A., Reiley, D. H., & Zhang, H. (2025). Personalizing Ad Load to Optimize Subscription and Ad Revenues: Product Strategies Constructed from Experiments on Pandora. *Marketing Science*, 44(2), 327–352. <https://doi.org/10.1287/mksc.2022.0357>

- Gomez-Uribe, C. A., & Hunt, N. (2016). The Netflix Recommender System: Algorithms, Business Value, and Innovation. *ACM Transactions on Management Information Systems*, 6(4), 1–19. <https://doi.org/10.1145/2843948>
- Graham, J., Haidt, J., Koleva, S., Motyl, M., Iyer, R., Wojcik, S. P., & Ditto, P. H. (2013). Moral foundations theory: The pragmatic validity of moral pluralism. In *Advances in experimental social psychology* (Roč. 47, s. 55–130). Elsevier. <https://www.sciencedirect.com/science/article/pii/B9780124072367000024>
- Grbovic, M., Radosavljevic, V., Djuric, N., Bhamidipati, N., Savla, J., Bhagwan, V., & Sharp, D. (2015). E-commerce in Your Inbox: Product Recommendations at Scale. *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1809–1818. <https://doi.org/10.1145/2783258.2788627>.
- Hann, I.-H., Hui, K.-L., Lee, S.-Y. T., & Png, I. P. L. (2007). Overcoming Online Information Privacy Concerns: An Information-Processing Theory Approach. *Journal of Management Information Systems*, 24(2), 13–42. <https://doi.org/10.2753/MIS0742-1222240202>
- Havas Media Network, Lumen Research, & Brand Metrics. (2024). *What Do 9,000 Brand Lift Studies Teach Us About Attention & Memory?*
- Heaven, W. D. 2025 *How DeepSeek ripped up the AI playbook—And why everyone's going to follow it.* MIT Technology Review. <https://www.technologyreview.com/2025/01/31/1110740/how-deepseek-ripped-up-the-ai-playbook-and-why-everyones-going-to-follow-it/>
- Hess, N. J., Kelley, C. M., Scott, M. L., Mende, M., & Schumann, J. H. (2020). Getting Personal in Public!? How Consumers Respond to Public Personalized Advertising in Retail Stores. *Journal of Retailing*, 96(3), 344–361. <https://doi.org/10.1016/j.jretai.2019.11.005>
- Ho, S. Y., & Bodoff, D. (2014). The effects of web personalization on user attitude and behavior. *MIS quarterly*, 38(2), 497-A10.
- Hofstede, G. (2011). Dimensionalizing cultures: The Hofstede model in context. *Online readings in psychology and culture*, 2(1), 8.
- Hyde, M., Gapminder, & UN WPP. (2024). *Number of people using the Internet* [Dataset]. <https://ourworldindata.org/grapher/number-of-internet-users>
- Chandra, S., Verma, S., Lim, W. M., Kumar, S., & Donthu, N. (2022). Personalization in personalized marketing: Trends and ways forward. *Psychology & Marketing*, 39(8), 1529–1562. <https://doi.org/10.1002/mar.21670>
- Cherry, E. C. (1953). Some experiments on the recognition of speech, with one and with two ears. *Journal of the acoustical society of America*, 25, 975–979.
- Jones, D. B., & Shaw, E. H. (2002). A history of marketing thought. *Handbook of marketing*, 39–65.

- Kaptein, M. (2018). Customizing persuasive messages; the value of operative measures. *Journal of Consumer Marketing*, 35(2), 208–217. <https://doi.org/10.1108/JCM-11-2016-1996>
- Katz, E., Blumler, J. G., & Gurevitch, M. (1973). Uses and gratifications research. *The public opinion quarterly*, 37(4), 509–523.
- Keith, R. J. (1960). The Marketing Revolution. *Journal of Marketing*, 24(3), 35–38. <https://doi.org/10.1177/002224296002400306>
- Kliman-Silver, C., Hannak, A., Lazer, D., Wilson, C., & Mislove, A. (2015). Location, Location, Location: The Impact of Geolocation on Web Search Personalization. *Proceedings of the 2015 Internet Measurement Conference*, 121–127. <https://doi.org/10.1145/2815675.2815714>
- Kučerová, H. 2003 *Vytěžování dat*. Databáze Národní knihovny ČR. https://aleph.nkp.cz/F/?func=direct&doc_number=000000088&local_base=KTD
- Kushnarevych, A., & Kollárová, D. (2023). Development of Artificial Intelligence as a Breakthrough for Personalization in Marketing. *2023 3rd International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME)*, 1–6. 2023 3rd International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME). <https://doi.org/10.1109/ICECCME57830.2023.10252550>
- Lambrecht, A., & Tucker, C. (2013). When Does Retargeting Work? Information Specificity in Online Advertising. *Journal of Marketing Research*, 50(5), 561–576. <https://doi.org/10.1509/jmr.11.0503>
- Laran, J., Dalton, A. N., & Andrade, E. B. (2011). The curious case of behavioral backlash: Why brands produce priming effects and slogans produce reverse priming effects. *Journal of consumer research*, 37(6), 999–1014.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436–444.
- Linden, G., Smith, B., & York, J. (2003). Amazon.com recommendations: Item-to-item collaborative filtering. *IEEE Internet Computing*, 7(1), 76–80. IEEE Internet Computing. <https://doi.org/10.1109/MIC.2003.1167344>
- Matz, S. C., Teeny, J. D., Vaid, S. S., Peters, H., Harari, G. M., & Cerf, M. (2024). The potential of generative AI for personalized persuasion at scale. *Scientific Reports*, 14(1), 4692. <https://doi.org/10.1038/s41598-024-53755-0>
- Matz, S., Kosinski, M., Nave, G., & Stillwell, D. (2017). Psychological targeting as an effective approach to digital mass persuasion. *Proceedings of the National Academy of Sciences*, 114, 201710966. <https://doi.org/10.1073/pnas.1710966114>
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (1955). *A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence*. <http://raysolomonoff.com/dartmouth/boxa/dart564props.pdf>

- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115–133.
- Mehmood, K., Verleye, K., De Keyser, A., (2022). Piloting personalization research through data-rich environments: A literature review and future research agenda. *Journal of Service Management*, 34(3), 520–552. <https://doi.org/10.1108/josm-10-2021-0405>
- Miles, J., & Shevlin, M. (2000). *Applying Regression and Correlation: A Guide for Students and Researchers*. SAGE.
- Mishra, B. K., & Kumar, R. (2020). *Natural language processing in artificial intelligence*. CRC Press.
- Murár, P. (2023). Bridging personalised marketing with artificial intelligence: An analysis of evolution and future trends. *Prostináková Hossová, M., Martovič, M., & M. Solík (Eds.), Media & marketing identity: AI the future of today*, 348–355.
- Murthi, B. P. S., & Sarkar, S. (2003). The Role of the Management Sciences in Research on Personalization. *Management Science*, 49(10), 1344–1362. <https://doi.org/10.1287/mnsc.49.10.1344.17313>
- Němeček, J. (2022). *Umělá inteligence jako nástroj pro personalizaci reklamy*. <https://dspace.cuni.cz/handle/20.500.11956/176307>
- Neurazitelny.cz (2019). *Umělá inteligence a život zítřka—Michal Pěchouček | Neurazitelny.cz | Večery na FF UK [YouTube Video]*. https://www.youtube.com/watch?v=ziY4Q7_LnQ8
- OMR (2017). *Alexander Nix: From Mad Men to Math Men | OMR Festival 2017—Hamburg, Germany | #OMR17 [YouTube Video]*. <https://www.youtube.com/watch?v=6bG5ps5KdDo>
- Ouyang, L., Wu, J., Jiang, X., Almeida, D., Wainwright, C., Mishkin, P., Zhang, C., Agarwal, S., Slama, K., & Ray, A. (2022). Training language models to follow instructions with human feedback. *Advances in neural information processing systems*, 35, 27730–27744.
- Pandey, A. (2023). *Computer Vision*. 2023(11). <https://doi.org/10.22214/ijraset.2023.54701>
- Patwardhan, N., Marrone, S., & Sansone, C. (2023). Transformers in the real world: A survey on nlp applications. *Information*, 14(4), 242.
- Peppers, D., & Rogers, M. (1993). *The one to one future: Building relationships one customer at a time*. Currency Doubleday New York. <https://core.ac.uk/download/pdf/299850176.pdf>
- Petty, R. E., & Cacioppo, J. T. (1986). The Elaboration Likelihood Model of Persuasion. In R. E. Petty & J. T. Cacioppo, *Communication and Persuasion* (s. 1–24). Springer New York. https://doi.org/10.1007/978-1-4612-4964-1_1

- Priyadharshini, A. K., & Mathew, S. K. (2016). The impact of individual privacy and personalization on online buying behavior: An experimental study. *2016 IEEE International Conference on Management of Innovation and Technology (ICMIT)*, 150–155. <https://ieeexplore.ieee.org/abstract/document/7605024/>
- Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., Sastry, G., Askell, A., Mishkin, P., & Clark, J. (2021). Learning transferable visual models from natural language supervision. *International conference on machine learning*, 8748–8763. <http://proceedings.mlr.press/v139/radford21a>
- Reed, O. (1949). Some Random Thoughts... On Personalizing. *The reporter of direct mail advertising, April*.
- Russell, S., & Norvig, P. 2021 *Artificial Intelligence, Modern Approach*. Pearson Deutschland. <https://elibrary.pearson.de/book/99.150005/9781292401171>
- Rust, R. T. (2020). The future of marketing. *International Journal of Research in Marketing*, 37(1), 15–26. <https://doi.org/10.1016/j.ijresmar.2019.08.002>
- Salvi, F., Ribeiro, M. H., Gallotti, R., & West, R. (2024). *On the Conversational Persuasiveness of Large Language Models: A Randomized Controlled Trial* (No. arXiv:2403.14380). arXiv. <http://arxiv.org/abs/2403.14380>
- Sandy, C. J., Gosling, S. D., & Durant, J. (2013). Predicting Consumer Behavior and Media Preferences: The Comparative Validity of Personality Traits and Demographic Variables. *Psychology & Marketing*, 30(11), 937–949. <https://doi.org/10.1002/mar.20657>
- Sheth, J. N., & Parvatiyar, A. (1995). The evolution of relationship marketing. *International business review*, 4(4), 397–418.
- Shin, M., & Kim, J. (2024). Large Language Models Can Enhance Persuasion Through Linguistic Feature Alignment. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4725351>
- Schreiner, M. 2023 *GPT-4 architecture, datasets, costs and more leaked*. THE DECODER. <https://the-decoder.com/gpt-4-architecture-datasets-costs-and-more-leaked/>
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., van den Driessche, G., Schrittwieser, J., Antonoglou, I., Panneershelvam, V., Lanctot, M., Dieleman, S., Grewe, D., Nham, J., Kalchbrenner, N., Sutskever, I., Lillicrap, T., Leach, M., Kavukcuoglu, K., Graepel, T., & Hassabis, D. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484–489. <https://doi.org/10.1038/nature16961>
- Smith, W. R. (1956). Product Differentiation and Market Segmentation as Alternative Marketing Strategies. *Journal of Marketing*, 21(1), 3–8. <https://doi.org/10.1177/002224295602100102>
- Stein, E., Robinson, K., Wolfer, A., Almeida, G., & Huang, W. (2025, leden 30). *The next frontier of personalized marketing* | McKinsey.

<https://www.mckinsey.com/capabilities/growth-marketing-and-sales/our-insights/unlocking-the-next-frontier-of-personalized-marketing>

- Stevens, S., & Hening, W. A. (2007). Chapter 2—Sleep and Wakefulness. In C. G. Goetz (Ed.), *Textbook of Clinical Neurology (Third Edition)* (s. 21–33). W.B. Saunders. <https://doi.org/10.1016/B978-141603618-0.10002-5>
- Sunikka, A., & Bragge, J. (2012). Applying text-mining to personalization and customization research literature – Who, what and where? *Expert Systems with Applications*, 39(11), 10049–10058. <https://doi.org/10.1016/j.eswa.2012.02.042>
- Surprenant, C. F., & Solomon, M. R. (1987). Predictability and Personalization in the Service Encounter. *Journal of Marketing*, 51(2), 86–96. <https://doi.org/10.1177/002224298705100207>
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (Second edition). The MIT Press.
- Štetka, P., & Grisáková, N. (2022). Cross-Cultural Segmentation: Hierarchical Clustering Analysis Using Hofstede’s Cultural Model. *Sustainable Business Development Perspectives 2022*, 262–277. *Sustainable Business Development Perspectives 2022*. <https://doi.org/10.5817/CZ.MUNI.P280-0197-2022-24>
- Tam, K. Y., & Ho, S. Y. (2005). Web Personalization as a Persuasion Strategy: An Elaboration Likelihood Model Perspective. *Information Systems Research*, 16(3), 271–291. <https://doi.org/10.1287/isre.1050.0058>
- Tappin, B. M., Wittenberg, C., Hewitt, L. B., Berinsky, A. J., & Rand, D. G. (2023). Quantifying the potential persuasive returns to political microtargeting. *Proceedings of the National Academy of Sciences*, 120(25), e2216261120. <https://doi.org/10.1073/pnas.2216261120>
- Tong, A., Wang, E., Coulter, M., Tong, A., & Wang, E. 2024 Exclusive: Reddit in AI content licensing deal with Google. *Reuters*. <https://www.reuters.com/technology/reddit-ai-content-licensing-deal-with-google-sources-say-2024-02-22/>
- Trefis Team. (2015). How NIKEiD Is Helping Nike’s Push For Greater Profits. *Forbes*. <https://www.forbes.com/sites/greatspeculations/2015/07/09/how-nikeid-is-helping-nikes-push-for-greater-profits/>
- Tsenov, D. (2013). *A BENEFIT-BASED APPROACH FOR INCREASING THE EFFECTIVENESS OF PROMOTIONS*. <https://www.semanticscholar.org/paper/A-BENEFIT-BASED-APPROACH-FOR-INCREASING-THE-OF-Tsenov/486d1f5b2c0f30b937ffe7f216bb1d488f03ec7>
- Turov, N., Shilov, N., & Teslya, N. (2019). Digital signage personalization through analysis of the visual information about viewers. *2019 24th Conference of Open Innovations Association (FRUCT)*, 444–450. <https://ieeexplore.ieee.org/abstract/document/8711893/>


- Tversky, A., & Kahneman, D. (1974). Judgment under Uncertainty: Heuristics and Biases: Biases in judgments reveal some heuristics of thinking under uncertainty. *Science*, *185*(4157), 1124–1131. <https://doi.org/10.1126/science.185.4157.1124>
- Tversky, A., & Kahneman, D. (1983). Extensional versus intuitive reasoning: The conjunction fallacy in probability judgment. *Psychological review*, *90*(4), 293.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, *30*. <https://proceedings.neurips.cc/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html>
- Vesanen, J. (2007). What is personalization? A conceptual framework. *European Journal of Marketing*, *41*(5/6), 409–418. <https://doi.org/10.1108/03090560710737534>
- Vesanen, J., & Raulas, M. (2006). Building bridges for personalization: A process model for marketing. *Journal of Interactive Marketing*, *20*(1), 5–20. <https://doi.org/10.1002/dir.20052>
- Villalobos, P., Ho, A., Sevilla, J., Besiroglu, T., Heim, L., & Hobbhahn, M. (2022). Will we run out of data? Limits of LLM scaling based on human-generated data. *arXiv preprint arXiv:2211.04325*. <https://kumarvignesh.com/wp-content/uploads/2025/01/2211.04325v2.pdf>
- Walrave, M., Poels, K., Antheunis, M. L., Van den Broeck, E., & van Noort, G. (2018). Like or dislike? Adolescents' responses to personalized social network site advertising. *Journal of Marketing Communications*, *24*(6), 599–616. <https://doi.org/10.1080/13527266.2016.1182938>
- Wang, J., & Biljecki, F. (2022). Unsupervised machine learning in urban studies: A systematic review of applications. *Cities*, *129*, 103925.
- Wedel, M., & Kannan, P. K. (2016). Marketing Analytics for Data-Rich Environments. *Journal of Marketing*, *80*(6), 97–121. <https://doi.org/10.1509/jm.15.0413>
- Wetzlinger, W., Auinger, A., Kindermann, H., & Schönberger, W. (2017). Acceptance of Personalization in Omnichannel Retailing. In F. F.-H. Nah & C.-H. Tan (Ed.), *HCI in Business, Government and Organizations. Supporting Business* (Roč. 10294, s. 114–129). Springer International Publishing. https://doi.org/10.1007/978-3-319-58484-3_10
- What is AI? / Basic Questions*. (2011). Stanford. <http://jmc.stanford.edu/artificial-intelligence/what-is-ai/>
- Williams, J. (2018). *Stand Out of Our Light: Freedom and Resistance in the Attention Economy*. Cambridge University Press.
- Xian, Y., Lampert, C. H., Schiele, B., & Akata, Z. (2018). Zero-shot learning—A comprehensive evaluation of the good, the bad and the ugly. *IEEE transactions on pattern analysis and machine intelligence*, *41*(9), 2251–2265.

- Xu, H., Luo, X. R., Carroll, J. M., & Rosson, M. B. (2011). The personalization privacy paradox: An exploratory study of decision making process for location-aware marketing. *Decision support systems*, 51(1), 42–52.
- Zarouali, B., Dobber, T., De Pauw, G., & De Vreese, C. (2022). Using a Personality-Profiling Algorithm to Investigate Political Microtargeting: Assessing the Persuasion Effects of Personality-Tailored Ads on Social Media. *Communication Research*, 49(8), 1066–1091. <https://doi.org/10.1177/0093650220961965>
- Zhang, J. (2011). The Perils of Behavior-Based Personalization. *Marketing Science*, 30(1), 170–186. <https://doi.org/10.1287/mksc.1100.0607>
- Zhang, J., Creighton, D., Lim, C. P., Rolfe, B., Weiss, M., Neiat, A., Zaslavsky, A., Nguyen, T., Navaei, J., & Gamasae, R. (2024). Anomaly Detection in the Automotive Stamping Process: An Unsupervised Machine Learning Approach. *IOP Conference Series: Materials Science and Engineering*, 1307(1), 012035. <https://iopscience.iop.org/article/10.1088/1757-899X/1307/1/012035/meta>
- Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., Min, Y., Zhang, B., Zhang, J., & Dong, Z. (2023). A survey of large language models. *arXiv preprint arXiv:2303.18223*, 1(2).
- Zhu, Y.-Q., & Chang, J.-H. (2016). The key role of relevance in personalized advertisement: Examining its impact on perceptions of privacy invasion, self-awareness, and continuous use intentions. *Computers in Human Behavior*, 65, 442–447. <https://doi.org/10.1016/j.chb.2016.08.048>

Teze diplomové práce

Institut komunikačních studií a žurnalistiky FSV UK Teze MAGISTERSKÉ diplomové práce	
TUTO ČÁST VYPLŇUJE STUDENT/KA:	
Příjmení a jméno diplomantky/diplomanta: Josef Němeček	Razítko podatelny:
Imatrikulační ročník diplomantky/diplomanta: 2022	
Fakultní e-mail diplomantky/diplomanta: 86797489@fsv.cuni.cz	
Studijní program/forma studia: Strategická komunikace / prezenční studium	
Název práce v češtině: AI jako politický stratég: Zkoumání dopadu mikrotargetingu a personalizačních technik na efektivitu kampaní	
Název práce v angličtině: AI as a Political Strategist: Investigating the Impact of Microtargeting and Personalization Techniques on Campaign Effectiveness	
Předpokládaný termín dokončení (semestr, akademický rok – vzor: ZS 2022/2023) (diplomovou práci je možné obhajovat nejdříve šest měsíců od schválení tezi) ZS 2024/2025	
Charakteristika tématu a jeho dosavadní zpracování (max. 1800 znaků): Tato diplomová práce se bude věnovat efektivitě personalizace a mikrotargetingu v rámci politické komunikace s využitím jak již tradičních nástrojů umělé inteligence, tak i nově vznikajících technologií. Teoretická část práce se zaměří na definici a pochopení klíčových pojmů a konceptů jako je umělá inteligence, personalizace, mikrotargeting, politická komunikace a psychologie přesvědčování. Autor dále představí, jaké technologie a algoritmy umožňují sofistikovanou segmentaci a cílení v politickém marketingu a jaké dopady mohou mít tyto strategie na voliče a celkový demokratický proces do budoucna. Empirická část pak bude postavena na designu experimentu, který bude mít za cíl vyhodnotit vliv různých typů marketingové personalizace v kontextu politických kampaní na chování a postoje voličů. Práce jako taková má za úkol rozšířit existující, ale velmi limitované výzkumné snahy dopadu mikrotargetingových a personalizačních marketingových strategií na rozhodování voličů.	
Předpokládaný cíl práce, případně formulace problému, výzkumné otázky nebo hypotézy (max. 1800 znaků): Cíl této diplomové práce je dvojitý: za prvé, podrobně zmapovat a popsat současné možnosti využití umělé inteligence v oblasti personalizované reklamy a mikrotargetingu v kontextu politické komunikace. To zahrnuje analýzu nástrojů, metod a algoritmů umožňujících sofistikované segmentování cílových skupin a přizpůsobení obsahu komunikace specifickým potřebám a preferencím jednotlivých voličů. Druhým cílem je pak empiricky ověřit reálné dopady těchto technologií na názory a postoje voličů.	
Předpokládaná struktura práce (rozdělení do jednotlivých kapitol a podkapitol se stručnou charakteristikou jejich obsahu): <ul style="list-style-type: none">• Úvod• Teoretická část<ul style="list-style-type: none">○ Umělá inteligence<ul style="list-style-type: none">▪ Strojové učení▪ Hluboké učení	

<ul style="list-style-type: none"> ▪ Natural Language Processing ○ Funkce umělé inteligence v digitálním obsahu <ul style="list-style-type: none"> ▪ Historie, aplikace a limitace ○ Politický marketing <ul style="list-style-type: none"> ▪ Definice politického marketingu ▪ Role psychologie přesvědčování ▪ Mikrotargeting a personalizace v politickém kontextu • Empirická část <ul style="list-style-type: none"> ○ Metodologie ○ Popis výzkumného souboru ○ Popis průběhu studie ○ Výsledky, diskuze a interpretace • Závěr
<p>Vymezení podkladového materiálu (např. titul periodika a analyzované období):</p> <ul style="list-style-type: none"> • Odborné a akademické články na téma umělé inteligence, dat či personalizace • Internetové články publikované na marketingově a technologicky zaměřených portálech
<p>Metody (techniky) zpracování materiálu: Studium odborných materiálů, experiment</p>
<p>Základní literatura (nejméně 5 nejdůležitějších titulů k tématu a metodě jeho zpracování; u všech titulů je nutné uvést stručnou anotaci na 2–5 řádků):</p> <p>TAPPIN, Ben M., et al. Quantifying the potential persuasive returns to political microtargeting. <i>Proceedings of the National Academy of Sciences</i>, 2023, 120.25: e2216261120.</p> <ul style="list-style-type: none"> • Tento výzkum se zaměřuje účinky politického mikrotargetingu, praktiky, která vyvolává obavy o jejím potenciálním vlivu na ovlivňování veřejného mínění a voleb. Autoři předkládají dvě hlavní studie zaměřené na USA, kde využívají strojové učení k určení, které reklamy ukázat kterým jednotlivcům, aby maximalizovali jejich přesvědčivost. <p>RUSSELL, Stuart J. Artificial intelligence: a modern approach / Stuart J. Russell and Peter Norvig. 2016. ISBN 9781292153964.</p> <ul style="list-style-type: none"> • Artificial intelligence: a modern approach je nejznámější vysokoškolská učebnice umělé inteligence. Autoři v této knize dávají umělou inteligenci do historického kontextu, definují ji a následně rozebírají její funkcionality. <p>MUTZ, Diana Carole; SNIDERMAN, Paul M.; BRODY, Richard A. (ed.). <i>Political persuasion and attitude change</i>. University of Michigan Press, 1996.</p> <ul style="list-style-type: none"> • Tato kniha se soustředí na politickou persuazi, což je téma, které se v porovnání s oblastmi jako jsou komunikace nebo psychologie, v daném kontextu nedostávalo tolik pozornosti. Text

<p>propojuje různé disciplíny, včetně kulturní a psychologické antropologie, kognitivní a klinické psychologie, ekonomie, komunikace a politické vědy.</p> <p>KREPS, Sarah; MCCAIN, R. Miles; BRUNDAGE, Miles. All the news that's fit to fabricate: AI-generated text as a tool of media misinformation. <i>Journal of experimental political science</i>, 2022, 9.1: 104-117.</p> <ul style="list-style-type: none"> • Studie, která pomocí tří experimentů zkoumá, zda texty vytvořené pomocí umělé inteligence působí věrohodně a mají schopnost ovlivňovat postoje k mezinárodním politikám a zda lze tyto texty využít pro šíření dezinformací. <p>MATTHEWS, Robert; ROSS, Elizabeth. <i>Research methods: A practical guide for the social sciences</i>. Pearson Education Ltd, 2010.</p> <ul style="list-style-type: none"> • Kniha výzkumných metod, která nabízí nejen teoretický základ, ale hlavně sadu příkladů z praxe nejrůznějších oborů a důkladnou analýzu toho, proč si výzkumníci vybírají metody, které používají. 	
<p>Diplomové a disertační práce k tématu (seznam bakalářských, magisterských a doktorských prací, které byly k tématu obhájeny na UK, případně dalších oborově blízkých fakultách či vysokých školách za posledních pět let)</p> <p>RICHTER, Martin. <i>Vliv umělé inteligence na vnímání kvality a důvěryhodnosti obsahu v digitální komunikaci</i>. Diplomová práce, vedoucí Slaviček, Daniel. Praha: Univerzita Karlova, Fakulta sociálních věd, Katedra marketingové komunikace a public relations, 2023.</p> <p>NĚMEČEK, Josef. <i>Umělá inteligence jako nástroj pro personalizaci reklamy</i>. Bakalářská práce, vedoucí Vranka, Marek. Praha: Univerzita Karlova, Fakulta sociálních věd, Katedra marketingové komunikace a public relations, 2022.</p> <p>MASSALEMA, Adham. <i>Využití umělé inteligence v grafickém designu pro marketingové účely</i>. Bakalářská práce, vedoucí Oukropec, Jindřich. Praha: Univerzita Karlova, Fakulta sociálních věd, Katedra marketingové komunikace a public relations, 2023.</p>	
<p>Datum / Podpis studenta/ky</p> <p>12.3.2024</p>	

<p>TUTO ČÁST VYPLŇUJE PEDAGOG/PEDAGOŽKA:</p> <p>Doporučení k tématu, struktuře a technice zpracování materiálu:</p>	
<p>Případné doporučení dalších titulů literatury předepsané ke zpracování tématu:</p>	
<p>Potvrzuji, že výše uvedené teze jsem s jejich autorem/kou konzultoval(a) a že téma odpovídá mému oborovému zaměření a oblasti odborné práce, kterou na FSV UK vykonávám.</p> <p>Souhlasím s tím, že budu vedoucí(m) této práce.</p>	
<p>Příjmení a jméno pedagožky/pedagoga</p>	<p>..... Datum / Podpis pedagožky/pedagoga</p>

Seznam obrázků

Obrázek 1 – Ukázka rozložení obrazovek v obchodech 1 a 3

Obrázek 3 – Ukázka zobrazení stimulů generické reklamy

Obrázek 4 – Ukázka zobrazení stimulů hyper-personalizované reklamy

Obrázek 5 – Náhled kreativ pro všechny produkty

Seznam grafů

Graf 1 – Demografické rozložení výzkumného souboru

Graf 2 – Deskriptivní histogram LLM odezvy mezi jednotlivými lokacemi

Graf 3 – Průměrná a mediánová doba zaujetí podle typu reklamy (H1)

Graf 4 – Vztah mezi dobou zaujetí a pravděpodobností nákupu (H3)

Graf 5 – Odhadované mezní průměry doby zaujetí podle věku a pohlaví ve dvou experimentálních podmínkách G vs. HP (VO1a)

Graf 6 – Procentuální zastoupení nákupního chování podle pohlaví mezi G a HP podmínkou (VO1b)

Graf 7 – Srovnání nákupního chování mužů podle typu podmínky G vs. HP (VO1b)

Seznam tabulek

Tabulka 1 – Výsledky t-testů a neparametrického testu pro porovnání doby zaujetí mezi podmínkami (H1)

Tabulka 2 – Deskriptivní statistiky doby zaujetí podle typu reklamy (H1)

Tabulka 3 – Míry vhodnosti regresního modelu pro predikci nákupu doporučeného produktu podle typu reklamy (H2)

Tabulka 4 – Regresní koeficienty modelu testujícího vliv typu reklamy na nákup doporučeného produktu (H2)

Tabulka 5 – Míry vhodnosti regresního modelu pro predikci pravděpodobnosti nákupu na základě doby zaujetí (H3)

Tabulka 6 – Regresní koeficienty modelu testujícího vliv doby zaujetí na pravděpodobnost nákupu (H3)

Tabulka 7 – Míry vhodnosti regresních modelů pro predikci pravděpodobnosti nákupu (H4a, H4b)

Tabulka 8 – Regresní koeficienty pro modely testující vlivy HP na pravděpodobnost nákupu (H4a, H4b)

Tabulka 9 – Výsledky analýzy rozptylu (ANOVA) pro dobu zaujetí podle věku a pohlaví (VO1a)

Tabulka 10 – Post hoc test rozdílů v době zaujetí zákazníka mezi pohlavími (VO1a)

Tabulka 11 – Metriky logistického regresního modelu a omnibus test významnosti prediktorů ve vztahu k nákupu (VO1b)

Tabulka 12 – Chí-kvadrát test nezávislosti mezi pohlavím a nákupním chováním (VO1b)

Tabulka 13 – Post hoc analýza rozdílů v nákupním chování podle pohlaví a experimentální podmínky (VO1b)

Tabulka 14 – Příklad vygenerovaných reklamních textů pro Aktivační vlasové sérum

Seznam schémat

Schéma 1– Znázornění vztahu pojmů (Arora et al., 2008)

Schéma 2 – Proces personalizace (Vesonen & Raulas, 2006)

Schéma 3 – Hierarchie pojmů umělé inteligence (Vasile, 2024)

Schéma 4 – Schéma umělé neuronové sítě (Nielsen, 2015)

Schéma 5 – Architektura systému dynamické hyper-personalizace v retailu

Schéma 6 – Struktura systémového promptu pro LLM

Seznam příloh

Příloha č. 1 – Modelové koeficienty logistické regrese s interakcí Podmínka × Věk (tabulka)

Příloha č. 2 – Kontingenční tabulka rozdílů v nákupním chování mužů mezi podmínkou HP a G (tabulka)

Příloha č. 3 – Post hoc test rozdílů v době zaujetí mezi věkovými skupinami (tabulka)

Příloha č. 4 – Kontingenční tabulka četností nákupu podle pohlaví (tabulka)

Příloha č. 5 – Chí-kvadrát test mezi experimentální podmínkou a nákupním chováním mužů (tabulka)

Příloha č. 6 – Náhled kreativ pro všechny produkty (obrázek)

Přílohy

Příloha č. 1 – Modelové koeficienty logistické regrese s interakcí Podmínka × Věk

Modelové koeficienty - Nákup jakéhokoliv produktu

Prediktor	Odhad	SE	Z	p	Poměr pravděpodobnosti
Intercept	0.84796	0.0574	14.7642	<.001	2.335
Podmínka:					
G – HP	-0.00399	0.0795	-0.0501	0.960	0.996
Věk:					
10s – 30s	12.71811	378.5929	0.0336	0.973	333737.155
20s – 30s	-0.14298	0.1452	-0.9846	0.325	0.867
40s – 30s	0.24287	0.1372	1.7698	0.077	1.275
50s – 30s	1.08690	0.2175	4.9968	<.001	2.965
60s – 30s	0.89251	0.2491	3.5824	<.001	2.441
70s – 30s	12.71811	309.1198	0.0411	0.967	333737.155
Podmínka * Věk:					
(G – HP) * (10s – 30s)	0.00399	437.1614	9.12e-6	1.000	1.004
(G – HP) * (20s – 30s)	0.22194	0.2177	1.0194	0.308	1.248
(G – HP) * (40s – 30s)	0.08776	0.1977	0.4439	0.657	1.092
(G – HP) * (50s – 30s)	-0.42680	0.2975	-1.4344	0.151	0.653
(G – HP) * (60s – 30s)	0.35949	0.3741	0.9609	0.337	1.433
(G – HP) * (70s – 30s)

Poznámka. Skupiny 10s a 70s nebyly vzhledem k extrémně nízkému počtu případů dále interpretovány

Příloha č. 2 – Post hoc test rozdílů v době zaujetí mezi věkovými skupinami

Post Hoc srovnání - Věk

Porovnání		Průměrný rozdíl	SE	df	t	Ptukey	Cohenova d
Věk	Věk						
10s	- 20s	-5.6950	5.457	4802	-1.04356	0.944	-0.37236
	- 30s	-7.2339	5.421	4802	-1.33455	0.836	-0.47299
	- 40s	-9.9289	5.443	4802	-1.82403	0.532	-0.64920
	- 50s	-9.8954	5.468	4802	-1.80960	0.542	-0.64700
	- 60s	-7.5379	5.490	4802	-1.37290	0.816	-0.49286
	- 70s	-7.2773	10.357	4802	-0.70265	0.992	-0.47582
20s	- 30s	-1.5389	0.764	4802	-2.01412	0.406	-0.10062
	- 40s	-4.2339	0.925	4802	-4.57806	<.001	-0.27683
	- 50s	-4.2004	1.056	4802	-3.97598	0.001	-0.27464
	- 60s	-1.8429	1.169	4802	-1.57664	0.697	-0.12050
	- 70s	-1.5823	8.869	4802	-0.17840	1.000	-0.10346
30s	- 40s	-2.6950	0.658	4802	-4.09516	<.001	-0.17621
	- 50s	-2.6614	0.831	4802	-3.20207	0.023	-0.17402
	- 60s	-0.3040	0.971	4802	-0.31301	1.000	-0.01987
	- 70s	-0.0434	8.848	4802	-0.00490	1.000	-0.00284
40s	- 50s	0.0336	0.983	4802	0.03418	1.000	0.00220
	- 60s	2.3911	1.103	4802	2.16875	0.313	0.15634
	- 70s	2.6516	8.861	4802	0.29926	1.000	0.17338
50s	- 60s	2.3575	1.215	4802	1.94060	0.453	0.15414
	- 70s	2.6180	8.877	4802	0.29494	1.000	0.17118
60s	- 70s	0.2606	8.890	4802	0.02931	1.000	0.01704

Poznámka. Srovnání jsou založena na odhadovaných mezních průměrech

Příloha č. 3 – Kontingenční tabulka četností nákupu podle pohlaví

Kontingenční tabulka

Podmínka	Nákup jakéhokoliv produktu		Pohlaví		Celkem
			F	M	
HP	0	Pozorované	596	53	649
		Očekávaný	591	58.2	649
		% v řádku	91.8%	8.2%	100.0%
	1	Pozorované	1575	161	1736
		Očekávaný	1580	155.8	1736
		% v řádku	90.7%	9.3%	100.0%
	Celkem	Pozorované	2171	214	2385
		Očekávaný	2171	214	2385
		% v řádku	91.0%	9.0%	100.0%
G	0	Pozorované	635	21	656
		Očekávaný	606	49.5	656
		% v řádku	96.8%	3.2%	100.0%
	1	Pozorované	1607	162	1769
		Očekávaný	1636	133.5	1769
		% v řádku	90.8%	9.2%	100.0%
	Celkem	Pozorované	2242	183	2425
		Očekávaný	2242	183	2425
		% v řádku	92.5%	7.5%	100.0%
Celkem	0	Pozorované	1231	74	1305
		Očekávaný	1197	107.7	1305
		% v řádku	94.3%	5.7%	100.0%
	1	Pozorované	3182	323	3505
		Očekávaný	3216	289.3	3505
		% v řádku	90.8%	9.2%	100.0%
	Celkem	Pozorované	4413	397	4810
		Očekávaný	4413	397	4810
		% v řádku	91.7%	8.3%	100.0%

Příloha č. 4 – Kontingenční tabulka rozdílu v nákupním chování mužů mezi podmínkou HP a G

Kontingenční tabulka

Nákup jakéhokoliv produktu		Podmínka		Celkem
		HP	G	
0	Pozorované	53	21	74
	% řádku	71.6%	28.4%	100.0%
1	Pozorované	161	162	323
	% v řádku	49.8%	50.2%	100.0%
Celkem	Pozorované	214	183	397
	% v řádku	53.9%	46.1%	100.0%

Příloha č. 5 – Chí-kvadrát test mezi experimentální podmínkou a nákupním chováním mužů

χ^2 Test

	Hodnota	df	p	Cramerovo V
χ^2	11.5	1	<.001	0.170
N	397			

Příloha č. 6 – Náhled kreativ pro všechny produkty



Aktivační vlasové sérum



Pleťové sérum Růže



SOS balzám



SPF krém Sedmikráska



Tělové mléko Sedmikráska



Toaletní voda Love Story



Pleťový olej Sedmikráska



Parfémová voda Ranní Louka



Pánská toaletní voda



Oční sérum Sedmikráska



Originální pивní šampón