

Porovnávání a hodnota dat

Vdávných dobách, kdy se zemí prohánely kočáry šlechticů, každý sám pro sebe si dokázal vzneseň jiného okamžíku zářdit do nejvýš společenské skupiny. Na druhém stupníku stála jména místní honorace - bohatých statkářů, vlastníků domů či obchodníků, kteří byli často i konšeli. Do střední společenské vrstvy patřili lidé vzdělání, lékaři, faráři, uředníci, učitelé, známí v širokém okolí. Bezejmenná většina poddaných tvorila tu nejvýše a současně nejméně společenskou skupinu. Tak si ke představit "první porovnávání" dat. Postupem doby se rozdily seřely a dnes již většinou není možné na základě samotného jména čistit společenské postavení té které osoby. Je nutno použít speciálních metod pro zvýšení marketingové hodnoty získané adresy.



Správná je prostřední verze adresy

V rámci direktmarketingové akce s jakýmkoli zaměřením není vhodné ani účelněj oslovovat každého člena rodiny samostatně. A již vůbec ne jednu osobu několikrát, v různých variantách. Tyto nedostatky v provedení výběru zbytečně zvyšují finanční náklady akce. Na základě dlouholetých zkušeností však konstatuji, že jsou poměrně časté, a to i u velkých direktmarketingových společností.

aneb co má společného šašek s králem

Samotný direktmarketing je postaven na pravděpodobnostní bázi, tzv. předpokladech. Jak k nim dospat? Pro získání kvalitních dat s maximem informací se využívají kromě jiných metod i dnes populární soutěže. Řada firem se snaží sbírat dat na bázi dobrovolnosti získat co nejodrobnejší údaje o soutěžících. Z počítáčově zpracovaných dataznaku jsou pak vytvářeny databáze potenciálních příjemců dalších nabídek, umožňující provést přesné cílené výběry pro konkrétní akce.

Často se při soutěžních akcích setkáváme s požadavkem na vyplnění osobních údajů, např. data narození. Nelze jednoznačně říci, že uvedená data vždy odpovídají skutečnosti. Mnoho lidí tato data zkresluje z obavy z jejich zneužití, ženy občas i z důvodu ještěnosti uvádějí svůj věk o několik let nižší. Správným přístupem je už v zadání dataznaku kategorizace věku a jiných osobních údajů do skupin, např. věkových (do 18, 18 až 30 let, atd.). Tako získaná data jsou daleko objektivnější, protože respondenti nemají pocit ohrožení, jako při požadavku na zadávání přesných údajů.

Vyplňování kupónů nebo odpovědných lístku je dobrovolné a záleží na každém respondentovi jak přesné údaje vyplnit. Je však nezbytný předpoklad, že vyplňné údaje jsou s nejvyšší pravděpodobností správné. Ve smyslu předpokladů by také měl být formulován obsah dopisu pro následnou mailingovou kampaně.

Při zpracování soutěží se často setkáváme se snahou respondentů poslat co nejvíce odpovědných lístků, aby zvýšili reálnou šanci na získání ceny. Zde se často setkáváme s geniální fantazií zájemců o ceny, kteří záměrně upravují nejen své identifikační ale i adresní údaje. Proto je potřeba použít speciálních algoritmů porovnávání pro odstranění duplicitních (redundantních) adres.

K tomuto účelu slouží první z porovnávacích mechanizmů, individuální porovnávání dat. Při získání vícenásobného výskytu adresy je důležité ponechat tu nejsprávnější a nejúplnější adresu. Pro názornost uvedém příklad individuální duplicity (multiplicity):



Jak je z příkladu patrné, nejsprávnější je teda adresa uprostřed a zbytečné adresy by měly být po porovnání s výše uvedenou odstraněny

S obdobnou situací se setkáváme i při výběru firem. Pro odstranění nadbytečných event. nesprávných záznamů lze použít poslední z porovnávacích mechanismů, a to turenní porovnávání dat. Např. firma A&A spol. s r.o. může být uvedena současně jako A+A s.r.o. nebo A a Sro. To se stává v případech, kdy jsou firemní adresy získávány z několika různých zdrojových databází. V rámci úspor nákladu je třeba rozpoznat a odstranit tento vícenásobný výskyt jedné a téže firmy.

Porovnávání dat slouží také pro obhacení původní databáze informacemi z jiných zdrojů, případně nalezení jednotlivých rodinných příslušníků (členů rodiny) nebo vyloučení již obeslaných klientů, případně vytvoření databáze nových potencionálních zákazníků, které nejsou součástí zákaznické databáze. Porovnávací algoritmy nejsou nikterak jednoduché a hodně záleží na zkušenostech v daném oboru.

Porovnávání dat a odstranění duplicitních adres v rámci přípravy databáze pro rozesílání nemusí být prováděno i nenekonkurenční (a trochu rizikantní) optickou kontrolou. Ize je usnadnit a racionalizovat využitím vhodného programu, který data před porovnáním upraví do správného tvaru.

V získaných adresách bývá mnoho nepřesností, dotazníky ze součtu nejsou vždy vyplňány správně nebo čitelně, navíc i při přepisu dat do databáze mohou vznikat nechtěné překlepy a zkromoleniny. Tomu lze snadno zabránit, a to nejlépe již v průběhu zápisu. K tomuto účelu slouží námi využitý software DEC2002 a Writer©2003 obsahující katalogy titulů, jmen, příjmení a adresní informační systém, který kompletně prověřuje všechny atributy a adresy, včetně čísel domů, PSČ a dodací pošty. Nesprávný zápis zastaví a nabídne varianty řešení. Tím lze odstranit i skryté chyby, pouhým okem snadno přehlédnutelné. Pokud budou veškeré adresy zapsány ve správném tvaru, lze pak porovnání, odstranění duplicitních adres a následné výběr cílové skupiny provést strojově. Jak by měla vypadat data po vyčištění:

Zde je příklad údajů, uvedených na soutěžním kupónu a po provedení zápisu pomocí uvedeného software:

Uvedeno jan novák ing. Csc. na trebes. 1441 100 99 prag jaroslav klegr mudr. na star. sil. 21-1 190 00 horn. pozec.	Zapsáno Ing. Jan Novák, CSc. Na Trebešině 16/1441 100 00 Praha 10 MUDr. Jaroslav Klegr Na Staré silničce 1/21 190 13 Praha 913
---	--

Po vyčištění a porovnání dat lze tedy přistoupit k analýze dat. Na základě samotné kompletní adresy lze získat poměrně dost informací. Samozřejmě, že zjištění hodnoty adresy je v duchu předpokladů a pravděpodobnosti. Vzhledem k tomu, že direktmarketing nepracuje s konkrétními subjekty, ale s jejich skupinami, lze teorií předpokladů úspěšně využít.

Jako první lze zjistit statistické údaje: počet mužů, žen, počet a akademických titulů (míru vzdělanosti), počet rodič, počet členů domácnosti, atd. V případě, že jsou v databázi obsažena data narození, případně věk, lze získat poměrně slušné informace o věkovém rozdílu, rozdílu dle znamení, atd. Zajímavé jsou i geografické informace obsažené v adresné části subjektů. Pomoci geografických informací lze zjistit chování zákazníků z různých oblastí, zjistit spádové oblasti, případně použitím statistických údajů míry nezaměstnanosti "usměrnit" rozesílání adresních mailingů do oblasti, kde lze předpokládat příznivější ohlas. Každá oblast má svá specifiká, využití kombinace všech dostupných informací vede k snížení nákladů na získání jednoho klienta.

Jaké informace lze získat ze samotné databáze obsahující jen osobu včetně titulu a adresné části? Ukažeme si na příkladu jedné virtuální čtyřčlenné rodiny, kolik informací lze získat.

Ing. Jan Novák, CSc., Na padelstím 37, 100 00 Praha 10, věk 28
Ivana Nováková, Na padelstím 37, 100 00 Praha 10, věk 26
Miriam Nováková, Na padelstím 37, 100 00 Praha 10, věk 4
JUDr. Milan Novák, Na padelstím 37, 100 00 Praha 10, věk 52

Kromě základních charakteristik, počtu mužů a žen v databázi, akademických titulů, oblasti, v níž žijí či podnikají, lze každou adresu rozložit na dílčí části a následně zařadit do skupin.

Zjištěné informace:

- vícečlenná rodina - shoda příjmení a adresy (je zde předpoklad, že je jedná o rodinu)
- rodina s výšim příjmy - na základě dosaženého vzdělání lze předpokládat i lepší společenské umístění
- rodina pochází z oblasti nízké nezaměstnanosti - dle statistických a geografických údajů
- rodina bydlí v členovém domě (dle AIS) a poblíž přehrady (Hostivař - geografické údaje)
- rodina bydlí v blízkosti obchodního komplexu - Interspar a v blízkos multikina - geografické údaje
- výši kupní síla - dle výše uvedených charakteristik a dle míry nezaměstnanosti
- rodina s výším vzděláním
- povolání právnik je obsaženo v rodině
- jedná se o mladou rodinu - Ivana je pravděpodobně manželkou Jana a mají dceru Miriam - dle udaného věku
- rodina s dítětem předškolního věku
- bydlí v společné domácnosti s rodiči - pravděpodobně řeší otázku bydlení - atd.

Hlavní databáze (předpoklad)	Detail adres dat I	Detail zdroj dat II	Detail zdroj dat III
J. Novák Litvínov 104 10000 Praha Ing. Josef Novák Litvínov 15/104 10000 Praha 10 Email: josef.novak@seznam.cz	Ing. Josef Novák Litvínov 15/104 10000 Praha 10 Email: josef.novak@seznam.cz	Josef Novák Litvínov 15 10000 Praha 10 Tel.: 232 557 250 Člen klubu VIP Věk 56 let	Miriam Nováková Litvínov 15 10000 Praha 10 Věk 12 let Nakupuje: Bartle

Vylepšená databáze (po porovnání)
Ing. Josef Novák Litvínov 15/104 10000 Praha 10 - Starý Jižní mž došroubu: Miriam Nováková Email: josef.novak@seznam.cz Věk 12 let

obr. 1 - Na obrázku je patrné, doplnění významné informaci z jiných zdrojů a vytvoření jedné kompletní databáze

Všechny tyto charakteristiky vychází z předpokladů, pomocí nichž lze vytvářet skupiny, určené pro adresou nabídku konkrétního druhu zboží nebo služeb. Zmíněnou virtuální rodinu bylo vhodné zařadit např. do skupiny pro nabídku

- pojištění dětí a mládeže
- zahraniční rekreace ve vyšší cenové hladině
- cvičení pro mladé ženy
- právnické literatury na CD
- získání bytu novou výstavbou
- baletní školy pro děti
- luxusního sortimentu zboží formou zásilkového prodeje
- osobního automobilu prestižní značky atd.

Když se vrátíme k úvodní otázce "co má společného Šašek s Králem" lze říci, že je to adresa trvalého bydliště, resp. působiště. Jistě najdete i další společné znaky jak již bylo výše popisáno.

Ing. Csibrey Daniel, ředitel společnosti DirectSoft, s.r.o.