

Studijní opora předmětu

Kvantitativní metody výzkumu v praxi

Jiří Šafr

Katedra řízení a supervize FHS UK

Email: <jiri.safr(AT)seznam.cz>

Poslední aktualizace: **8. 2. 2017, verze 0.7**

Obsah

Úvod	2
Orientační schéma: co a proč potřebuji vědět při přípravě dotazníkového šetření	4
K čemu příprava výzkumu a sběr dat vlastně směřuje?	5
Kvalita dat: Reprezentativita, reliabilita a validita	7
Data – datová matice	9
Znaky, jejich typy a role v hypotézách.....	12
Poznámky k operacionalizaci – měření proměnných.....	16
Jak intuitivně na ověření platnosti hypotézy (druhého řádu) – příklady	19
Když jsou znaky tři (či více) a možnosti–limity empirického prokázání kauzálních vztahů	24
Cíle výzkumu.....	25
Úrovně měření, analytická jednotka a volba designu výzkumu.....	26
Výzkumný design – typy uspořádání výzkumu.....	29
Pravidla a doporučení pro přípravu výzkumu (zatím jen vybraná)	31
Literatura	34

Upozornění: Jedná se o první část průběžně aktualizovaného studijního materiálu pro kurz KMVP (YMR05POZI). V této verzi 0.7 zatím schází detailnější příklady operacionalizace a s tím související přístupy k měření znaků pomocí otázek v dotazníku (mj. příklady typů/designů otázek). Najdete je ale podrobně rozpracované v prezentaci 3b na stránce <http://kmvp.wz.cz>, kde je také vždy nejaktuálnější verze tohoto textu.

Tato publikace vznikla jako součást řešení projektu *Inovace a rozšíření výuky výzkumných metod ve studijním programu Řízení a supervize v sociálních a zdravotnických organizacích* v rámci institucionálního plánu FHS UK pro rok 2015.

Úvod

Realizovat „kvantitativní“ sociologický výzkum, ba dokonce si jen jeho realizaci v konkrétních krocích představit, je pro někoho, kdo s ním nemá zkušenosti poměrně obtížné, i když se to na první pohled zdá jednoduché. Tento text chce ukázat, že představa o tom, že přeci stačí tzv. „rozdat dotazníčky“ a pak je nějak „posčítat“, je mylná a vede povětšinou, byť pravda ne výhradně, k riziku, že zbytečně možná otrávíte spoustu lidí a stejně se nic zásadního nedozvíte, tedy že výzkum a celá práce s ním spjatá bude možná tak trochu zbytečná.

Na základě zkušeností s výukou, nejvíce asi během zkoušení, si v tomto učebním textu kladu za cíl jednak objasnit ty nejzákladnější principy, jak a hlavně proč ve výzkumu postupovat a jednak čeho se vyvarovat.

Studenti mají k dispozici legendární knihu Miroslava Dismana *Jak se vyrábí sociologická znalost* (1993), která je vynikajícím úvodem do sociologického výzkumu, pro studenty oboru Řízení a supervize však v některých ohledech není zcela dostačující.

V tomto textu se proto omezíme jen na velmi zkrácené vysvětlení principů, způsobů uvažování o designování jednoduchých studií především v oblasti řízení a sociální práce/zdravotnictví (vlastně tak jde většinou o případové studie z určitého prostředí organizací), které v uvedené knize nejsou, s tím, že obecně číst jen tento text nestačí (na konci jsou proto uvedeny odkazy na literaturu, kde se dozvíte více).

Ve výkladu reflektuji jednak zkušenosti z více jak desetileté výuky kurzu KMVP, zejména pokud jde o konzultace a vedení diplomových prací a také svou vlastní sociologickou praxi z výzkumu, krom toho realizovaného přímo na KŘS FHS (ta je pravda poněkud limitovaná), také především v Sociologickém ústavu AV ČR, v.v.i., a dříve také na ISS FSV UK. Můj sociologický zájem se již léta soustřeďuje především o problematiku sociálních nerovností, kulturní participace a sociálních sítí resp. sociálního kapitálu. Ukázky z praxe výzkumných postupů si proto budeme demonstrovat mj. na některých z těchto témat.

Výklad v tomto textu se poněkud liší od standardních učebnic. V nich bývá povětšinou chronologicky uspořádán, tak jak postupujeme ve výzkum od první přípravné fáze – formulace problému, přes volbu sběru dat, přípravu výzkumného nástroje, sběr dat, až po fázi analýzy dat, jejich interpretace a sepsání výsledků. Letitá zkušenost s výukou však ukazuje, že to nemusí být zrovna nejefektivnější postup zejména v podmínkách výuky v rámci nesociologických oborů, tedy ve zkrácené značně zhuštěné podobě. Jako student oboru sociologie totiž máte výhodu v tom, že výuka přípravy výzkumu (to je zhruba téma našeho kurzu) většinou probíhá paralelně s výukou analýzy dat (statistiky) a nějakého obecně metodologicky zaměřeného kurzu, což výrazně podněcuje představu, k čemu to celé vlastně směřuje a jak to na sebe navazuje.

Stává se totiž, že studenti nesociologických oborů se naučí víceméně nazpaměť popis různých metod a celého postupu, aniž by ale pochopili, co výzkumný proces vlastně je,

k čemuž výrazně přispívá fakt, že si sami vlastně výzkum ani nevyzkouší, čímž mám na mysli především fázi analýzy vzniklých dat a to alespoň v té nejjednodušší bivariátní podobě. Jinými slovy, neprojdou pro laika bolestným procesem ověřování hypotéz, nebo si výzkum vyzkouší právě jen jako sběr dat (tj. „seberou dotazníčky“, maximálně výsledky z něj nanejvýš nějak jednoduše deskriptivně popíší) a to bohužel nezřídka bez hlubší přípravy designu výzkumu (definice jednotek měření a jednotek analýzy, metoda výběru z populace, kvalita měřících nástrojů atd.). Druhou věcí je utvoření si určité celkové výzkumné skepse, tedy spíše opatrnosti a obezřetnosti, k možnostem zobecňování zjištění na základě dotazníkového šetření (o tom bude ještě řeč). Tu vás standardní učebnice nenaučí (Dismanova *Jak se vyrábí sociologická znalost* je čestnou výjimkou). Proto tedy náš výklad začneme jakoby od konce – co vlastně dostaneme v podobě sebraných výzkumných dat a co s tím můžeme dále dělat, pokud jsme si kladli nějaké otázky a formulovali hypotézy. Konkrétně řečeno začneme od dat a vztahu mezi hodnotami dvěma znaků (např. v kontingenční tabulce). Naučíme se tedy myslet ve „vztazích mezi znaky“, takže k tomu potřebujeme nejprve vědět, co je to proměnná/znak (což jsou synonyma) a co hypotéza (druhého řádu). Dále si řekneme o problému měření. To nás pak logicky zavede k problematice ověřování reliability a validity. Naplnění cíle, který ve výzkumu budeme sledovat, tj. naše výzkumné otázky, bude vyžadovat určitý výzkumný design, takže si musíme říci také něco o různých formách uspořádání studie (zejména z hlediska role času a volby srovnávacích skupin).

Tento text má posloužit především pro přípravu na praktickou část zkoušky z předmětu KMVP, což znamená vypracování seminární práce (tj. výzkumného projektu včetně nástroje sběru dat) a také prakticky orientovaných otázek v testu (typu např. „Jakými konkrétními kroky byste ověřili hypotézu ...?“). Zdůrazňuji – neobsahuje tedy celou látku předmětu KMVP (tedy alespoň zatím),¹ to tedy znamená, že **krom tohoto textu musíte číst také povinnou a doporučenou literaturu a presentace k přednáškám dostupných na webových stránkách kurzu <http://kmvp.wz.cz>** (zejména Disman 1993). Zde se zkrátka zaměříme toliko na to, co vás standardní učebnice až tolik naučit nemohou.

Doufám ale, že tato studijní opora přispěje hlavně k praktické přípravě vašich vlastních výzkumů zejména pro diplomové práce a v rámci vaší pracovní orientace najde uplatnění v praxi. A když už sami přímo výzkum (nebo jeho jednotlivé fáze) realizovat nebudete, tak se alespoň stanete jeho poučeným zadavatelem. Přehled, který zde najdete, nabízí jen základní orientaci – jakousi mapu, věřím proto, že ve vás vyvolá potřebu a zájem přečíst si odborné metodologické texty, které v žádném případě nemůže nahradit.

¹ V textu nenajdete informace mj. k porovnání kvantitativního s kvalitativním výzkumem, volbě výzkumné strategie, technikám sběru dat, problematice standardizace, fází výzkumu a postupu výzkumníka, postupu a typům výběrů z populace, problematice návratnosti, různých typů dotazníků a způsobům jejich administrace, konstrukce a uspořádání dotazníku, typů otázek, jejich formulace a řazení (chybné formulace otázek), problémům a limitům standardizovaného dotazování ani etice výzkumu. Navíc problematika zkreslení a kvalita měření (validita, reliabilita, reprezentativita) jsou pojednány jen z části a taktéž vyžadují další čtení. Prakticky všechna tato témata jsou důkladně popsána v [Disman 1993].

Orientační schéma: co a proč potřebuji vědět při přípravě dotazníkového šetření

Cíl výzkumu = odpovědět na obecnou otázku, která se vztahuje k problému, který chci prozkoumat a to ve vztahu k populaci, na kterou chci výsledky zobecnit. Pokud jde o hlavní fenomén, který budu zkoumat, je-li příliš obecný a široký, pak ho potřebuji nějak konkrétněji uchopit → konceptualizovat. Obecná otázku převedu do konkrétních dílčích výzkumných otázek. Zjednodušeně řečeno, výzkumná otázka hledá odpověď na vztah mezi dvěma (a více) proměnnými → formuluji hypotézu, ta na danou otázku nabízí možnou odpověď, v ní figurují minimálně dva znaky.² Co je to hypotéza? Co je to znak/proměnná? (jeho úrovně měření; role v hypotéze) potřebuji mít konkrétní postup a nástroj pro měření dané proměnné – operacionalizaci (zde volíme řešení v rámci dotazníku, ale jsou i jiné metody) → Co je to operacionalizace? → volím nástroj a formu sběru dat* + design šetření (dále jen pro metodu sběru dat pomocí dotazníku) → Typ dotazníku (různé formy interakce s respondentem)* → Jakou konkrétní formou budu operacionalizovat znak v dotazníku? → Jaké existují formy/typy otázek v dotazníku? Mám seznam proměnných, co potřebuji změřit, mám definované hlavní vztahy v hypotézách a v kontextu v modelu vztahů a k jednotlivým znakům mám konkrétní znění otázek → sestavím je do dotazníku (podle pravidel dramaturgie)* → první verzi dotazníku podrobím pre-testu (pilotáži)* → výsledky pilotáže vyhodnotím a dotazník případně upravím → stanovím přesně metodu výběru z populace* a plán postupu při sběru dat → nasbírám data (např. provedu face-to-face rozhovory se záznamem do dotazníku)* → odpovědi z jednotlivých dotazníku vložím do datové matice (elektronický záznam) → Co to je a jak vypadá datová matice? Pořízenou první verzi dat vyčistím a případně data upravím, mj. vytvořím nové „syntetické“ proměnné, což souvisí s jejich zvolenou operacionalizací. Provedu první průzkumové analýzy k ověření rozložení naměřených hodnot. Případně provedu metodologicky náročnější analýzy ověřující kvalitu dat, např. zhodnocení reliability a validity měření (→ byla použita operacionalizace produktivní?). Provedu deskriptivní analýzu výsledků – tzv. třídění 1. stupně pro hlavní znaky, ty které mne zajímají hlediska výzkumné otázky (svižně – nenudivě je napíši do textu; tabulky/grafy zde většinou až do přílohy). Připravím výstupy třídění druhého stupně, v němž odpovídám na dílčí výzkumné otázky a tedy i intuitivně ověřuji své hypotézy zatím jen pomocí explorační analýzy (exploračně proto, že k jejich přesnějšímu ověření je většinou třeba ještě použít statistické testy). Výsledky názorně (graficky) zobrazím a dále je věcně interpretuji a zhodnotím, tj. nestačí jen popisovat, co je v datech, ale dát tomu význam v širším kontextu včetně diskuse limitů mého šetření (nebojím se metodologické skepse).

Krom věcí označených *, které máte podrobně popsány v literatuře [Disman 1993] a v prezentacích z přednášek a také těch souvisejících s analýzou dat (malým písmem),³ se vše dozvíte v následujícím textu.

² Zde jde o hypotézu druhého řádu (tj. vztahy mezi znaky). Hypotéza prvního řádu by jen popisovala očekávané hodnoty/ jejich rozložení u jednoho znaku, což je málo zajímavé a neproduktivní. Posuďte sami, k čemu nám bude hypotéza 1. řádu: „Mezi klienty je polovina (50%) nezaměstnaných.“ Proč právě „polovina“, jak jsme na to přišli? A kde je pro nás přesně hranice „poloviny“? (při 47 % budeme hypotézu zamítat?, a co při 52 %?). To se raději ptejme jen dobrými výzkumnými – zjišťovacími otázkami (explorační – průzkumné otázky), např. Jaký je podíl klientů služby, kteří nemají pravidelnou práci? Nebo, jaké jsou představy zaměstnanců o budoucím směřování organizace?

³ Jednoduchá analýza dat je vyučována v navazujícím nepovinném kurzu **Praktikum elementární analýzy dat**.

K čemu příprava výzkumu a sběr dat vlastně směřuje?

aneb *kvantitativní data = proměnné, proměnné, proměnné...*

Začneme nejprve tak trochu od konce, abychom lépe viděli, k čemu příprava výzkumu a sběr dat vlastně ve výsledku je. Řečeno velmi zjednodušeně v jedné větě: v sociální realitě naměříme zástupce jevů/vlastností – říkáme jim proměnné (nebo také znaky) a pak zkoumáme vztahy mezi nimi. Tyto vztahy nám předem předpověděly naše výzkumné otázky/hypotézy, které se snažíme v analýze ověřit či vyvrátit.

Nejprve ale ve zkratce několik pojmů, které později upřesníme a doplníme o další.

Proměnná=znak představuje symbolického zástupce jevu/vlastnosti (např. spokojenost nebo věk), co hodláme měřit. Znak může nabývat různých hodnot (odtud název „proměnná“), bezpodmínečně musí mít alespoň dvě hodnoty a ty by měly odpovídat stavům jevu/vlastnosti v realitě (znak nemusí mít bezpodmínečně tolik hodnot, kolik stavů může nastat u jevu/vlastnosti, ale musíme být schopni každý stav/vlastnost k nějaké hodnotě našeho znaku přiřadit).⁴ V sociální realitě, pokud máme měření založené na výpovědích lidí je měření bohužel vždy nedokonalé a tudíž tu více, jindy méně, zkreslené.

Výzkumné otázky se ptají po vztazích mezi proměnnými (případně jejich hodnotách).

Hypotézy jsou výroky o očekávaných vztazích mezi znaky (či rozložení hodnot znaku), ty se snažíme výzkumem ověřit. Popisují jev, jeho příčiny, mechanismy, a podmínky, jak za kterých a jak k němu dochází. Dávají tedy jednu z možných odpovědí na výzkumné otázky.

Učebnice definují kvantitativní sociologický výzkum (nic jiného než) jako proces testování hypotéz. V této souvislosti hovoříme o logice dedukce, kdy posupujeme jakoby „odshora dolu“: Předem máme hypotézu/y a jejich platnost se snažíme ověřit nebo zamítnout. To tedy znamená, že musíme mít hypotézy předem rozmyšlené a formulované připravené – ponechme teď stranou fázi přípravy měřícího nástroje i celou fázi sběru dat – k tomu nám poslouží teorie, což je velmi zjednodušeně řečeno suma zobecněných poznatků („návod jak to vlastně má fungovat“).⁵ Jenže teorie jsou tady od toho, abychom je neustále ověřovali (tedy přesněji řečeno snažili se je vyvrátit, protože teorii nelze nikdy bezvýhradně jednou provždy potvrdit) a to právě na základě poznatků empirického výzkumu. Kdyby pro nic jiného, tak už jen proto, že společnost/lidé/organizace atd. se neustále mění, navíc je nezbytné platnost hypotéz ověřovat v odlišných (kulturních) podmínkách (neustále je tedy vystavovat falzifikaci).

⁴ Kupříkladu, když zjišťujeme počet dětí, řekněme, že hodnoty naměřeného znaku jsou dány výzkumníkem předpřipravenými odpověďmi na otázku: žádné (tj. 0), 1, 2, 3, 4, a po této možnosti již následuje jen odpověď „5 a více“, pak tato poslední hodnota námi definovaného znaku v sobě zahrnuje všechny další hodnoty reálného jevu – počtu dětí (z nějakého důvodu totiž nepotřebujeme znát detailně konkrétní počet dětí nad 5).

⁵ Poněkud přesněji, teorie je „dobře podložený a konzistentní systém pojmů a tvrzení vysvětlující určitý okruh jevů (a umožňující jejich predikci), vytvořený na základě vědecké metody a zahrnující fakta, zákony, soudy a hypotézy, jejichž platnost byla opakovaně prokázána experimentálně či pozorováním“. [<http://slovník-cizich-slov.abz.cz/web.php/slovo/teorie>]

Jakmile získáme data, tak již nic jiného dělat nemůžeme, než na datech naše hypotézy buď potvrdit anebo vyvrátit, i když s tím vyvrácením a potvrzením je to složitější [viz Disman 1993]. Přísně vzato nemuseli bychom ani v kvantitativním výzkumu postupovat takto striktně, mohli bychom prostě „sbírat co nejvíce dat“ a v nich pak teprve „něco hledat“, jak si ale dokážete jistě představit, tak toto není dobrá, rozuměj efektivní, cesta pro organizaci kvantitativního výzkumu.⁶

Nicméně někdy se skutečně může uplatnit i v kvantitativním výzkumu přístup induktivní (ten, jak víte, je typický pro výzkum kvalitativní), při němž hledáme pravidelnosti „zdola z dat“ a ty se snažíme zobecnit (do teorie), nejčastěji tehdy kdy jsou za nějakým jiným účelem jaksí automaticky sbírána data, která je pak možno analyzovat, aniž by jejich vznik byl bezprostředně spjat s nějakou analytickou otázkou. Příkladem může být třeba existující databáze klientů se spoustou informací, které se o nich průběžně v souvislosti s čerpáním služeb zaznamenávají. Bohužel se obdobná situace někdy stane i studentům při jejich výzkumech realizovaných např. pro diplomovou práci a to tehdy, když si předem v přípravné fázi nedostatečně definovali výzkumné otázky a hypotézy a pak teprve nad sebranými daty vymýšlejí, jaké hypotézy by se z toho daly zformulovat a ověřovat. Jistě tušíte, že tohle rozhodně není dobrá cesta, jak něco kloudného vybádat.⁷

Dodejme, že na první pohled trochu jiný postup nastává při tzv. sekundární analýze dat, tj. pokud sami terénní sběr dat neprovádíme, nýbrž analyzujeme data, která před námi sbíral někdo jiný, většinou s poněkud jinými cíli (někdy jsou naše cíle identické a lišit se mohou jen postupy analýzy i způsob interpretace výsledků). Zdůrazněme, že jde stále o deduktivní přístup, protože otázky a hypotézy jsme si definovali před samotnou analýzou dat.

⁶ Pravda, existují velké výzkumy, nejčastěji jde o mezinárodní projekty, které sledují určité jedno či několik tematických zaměření, a přitom mají za cíl vytvářet data dostupná pro širokou komunitu vědců (a také studentů), kteří je mohou využívat pro zkoumání vlastních výzkumných otázek, aniž by sami stáli u zrodu výzkumu. Je to efektivní, protože to umožňuje sdílet vysoce kvalitní data (s rozsáhlými výběry a rigorózní metodologií jejich vytváření). Příkladem budiž projekty *ISSP – International Social Survey Programme* www.issp.org, *ESS – European Social Survey* <http://www.europeansocialsurvey.org> nebo *EVS – European Values Survey* www.europeanvaluesstudy.eu.

⁷ Tím rozhodně nechci tvrdit, že nás v rámci řádně rozmyšleného plánu výzkumu, po provedeném sběru dat a jejich prvotní analýze v souladu s předpřipravenými hypotézami, nemohou během analýz napadnout i další otázky (a tedy i hypotézy), které budou naše poznání zpřesňovat a prohlubovat. Naopak, to je na kvantitativním výzkumu možná ta nejzajímavější a také neopomenutelná fáze, ostatně jde o součást postupu elaborace.

Kvalita dat: Reprezentativita, reliabilita a validita

Tři parametry **kvality měření** (nejen) **v kvantitativním výzkumu**, které ovlivní přesnost získaných dat a tedy to, do jaké míry budou vaše závěry zobecnitelné, jsou: *Validita*, *Reliabilita* a *Reprezentativita*.

Začněme tou poslední – **reprezentativitou**, která je intuitivně nejjednodušeji pochopitelná. Reprezentativní data budete mít tehdy, když ve výběrovém souboru budou zastoupeny vlastnosti stejnou měrou jako v celé populaci a to nejen ty co měříte/zkoumáte a nebo jsou „viditelné“, ale i ty co přímo neměříte anebo jsou „neviditelné“ a možná vás z hlediska cílů výzkumu ani nezajímají. Proč i ty co nejsou na první pohled vidět? Protože tyto jevy/vlastnosti (proměnné) vztahy mezi proměnnými mohou zkreslovat. Tuto vlastnost je nám schopen bez výhrady zajistit jen pravděpodobnostní – náhodný výběr a to ještě v situaci, kdy se jedná o „dostatečně velký“ výběr z „velké“ populace.

Hypotetický příklad zkreslení s vychýleným – nereprezentativním výběrem. Chceme zkoumat příčiny fluktuace zaměstnanců ve společnosti s více organizačními jednotkami. Cílem výzkumu je zjistit, jak úmysl opustit organizaci souvisí s délkou zaměstnání ve firmě (tj. počet let u stávajícího zaměstnavatele). Z nějakého důvodu se nám nepodařilo získat reprezentativní data za všechny zaměstnance společnosti, například proto, že se nám nechtělo do vzdálených poboček. Máme hypotézu: Náchylnější k opuštění firmy jsou zaměstnanci, kteří již nějakou dobu ve firmě pracují ale zase ne tak dlouho. Jinými slovy, očekáváme, že chuť odejít u zaměstnanců, kteří zde pracují řekněme 5-9 let je výrazně vyšší než mezi nováčky či naopak seniory (10 a více let). Vztah mezi roky zaměstnání ve firmě a záměrem odejít je tedy podle naší hypotézy nelineární, křivka má tvar obráceného písmene U.

Získali jsme data, například prostřednictvím dotazníkového šetření pomocí face-to-face rozhovorů. Jejich analýza ukázala, že podíl těch, co by chtěli odejít je v jednotlivých skupinách podle délky zaměstnání u organizace zhruba stejný. Docházíme tedy k závěru, že záměr opustit společnost s dobou zaměstnání nesouvisí. Naší hypotézu bychom tedy mohli zamítnout (správně řečeno nepotvrdit). Skutečně? V našich datech ale chybí oddělení Z, které je typické tím, že jsou tam právě koncentrovány určité profese typu A, zatímco na centrále, kde jsme kvůli „operativnosti“ provedené výzkumu, či spíše naší pohodlnosti, vytvořili výběrový soubor a provedli šetření zaměstnanců, se ale shodou okolností koncentrují nováčci (zaučující se v centru) a také zde pracují seniory (v centrále působí zkušení lidé na řídicích pozicích). Předpokládejme v tomto našem hypotetickém příkladu, že fluktuace – potřeba odejít je obecně méně častá u čerstvých nováčků (teprve se rozkoukávají) a pak na druhé straně u dlouhodobých loajálních zaměstnanců, kteří ve společnosti pracují řekněme deset a více let, těch kteří ve firmě zakotvili, vydobyli si určité postavení a jsou k ní loajální. A co když z nějakého důvodu jsou právě na vzdálené pobočce Z koncentrováni zaměstnanci, co jsou ve firmě řekněme 5–9 let? Tedy ti, kteří již vědí „jak to chodí“ a mohou být proto citliví na problémy v organizaci práce a zároveň ve firmě nejsou

tak dlouho, aby u nich došlo ke ztotožnění s jejími strukturami a cíli. Jaké to bude mít důsledky pro naše data? Zkrátka takoví zaměstnanci budou ve výběru výrazně podprezentováni, což ve výsledku může vést k tomu, že naše zamítnutí (nepotvrzení) hypotézy bylo chybné, protože kdyby ve výběrovém souboru byli zástupci ze všech poboček, tak bychom očekávaný vztah v datech pravděpodobně našli.

Jenom na okraj, pokud by ve firmě již k masivním odchodům docházelo, pak by takovýto výzkum byl pravděpodobně z kategorie zbytečných, neboť bychom znali počty odcházejících podle jednotlivých oddělení/poboček a již to by nám mohlo v prvním kroku indikovat, kde by mohl být problém.

Reliabilita je spolehlivost vašeho měřicího nástroje – v dotazníkovém šetření, např. část dotazníku nebo i jedna otázka. „Data jsou reliabilní, když se při nezávislém opakování měření téže nezměněné vlastnosti u téhož objektu a za stejných podmínek získaný údaj nemění, resp. se změní jen velmi málo“. [Řehák, Řeháková 1986: 38] Ověřovat tuto vlastnost můžeme buď opakováním dotazování stejných otázek na stejných respondentech s určitým časovým odstupem (pretest–postest reliabilita) anebo pomocí paralelního měření v jednom čase (konzistence odpovědí na podobné otázky v jednom dotazníku), pak hovoříme o tzv. položkové reliabilitě. V každém případě k vyšší reliabilitě otázek v dotazníku přispívá formulování co nejurčitějších otázek a možných odpovědí, jejichž nabídka musí být adekvátní a přitom ovšem v rozumném rozsahu (vždyť kdo bude pozorně číst či poslouchat extrémně dlouhý seznam všech možných odpovědí?). Vyvarujete se neznámých slov, nekonkrétních dlouhých otázek a nejednoznačně formulovaných nabízených odpovědí a také otázek na názory a postoje, které respondenta nezajímají (tehdy hrozí, že odpovědi budou víceméně náhodné a tedy i nereliabilní, navíc nejspíše i nevalidní).

(zde bude ještě doplněno, zatím viz prezentaci z přednášek 3a a 3b)

Validita představuje obsahovou platnost. Nejobecněji ji můžeme definovat jako situaci (v datech), kdy to co jste měřili je to, co jste chtěli měřit. Vypadá to možná na první pohled jako zbytečnost, tak jednoduché to ale není. Tohle je dost možná největší kámen úrazu v kvantitativním výzkumu. Zatímco pro KVV je příznačná reprezentativita, pokud si ji zajistíme v designu studie a také při samotné realizaci sběru dat ohlídáme(!), reliabilitu jsme většinou schopni zlepšovat a to i díky tomu, že se relativně dobře dá měřit, tak s validitou mohou být problémy. Zejména pokud jde o měření postojů, názorů, hodnot ale nezřídka i pokud jde o reportování rádooby „objektivních“ údajů o chování, hlavně pokud jde o věci, které si nepamatujeme či si je jen obtížně vybavujeme z paměti a pak pochopitelně tam, kde si „pamatovat nechceme“ (a nebo si schválně vymýšlíme, protože chceme být viděni v lepším světle), tj. u sociálně ne/žádoucího jednání. Jinou otázkou je měření složitých konceptů, které zkrátka nelze validně zachytit „jednou otázkou v dotazníku“. Zkrátka validita je tak trochu velký „black-box“ a s jejím ověřováním je to značně komplikované.

Více o reliabilitě a validitě najdete v [Disman 1993: 62–70].

Data – datová matice

Pokud jako metodu sběru dat používáme dotazník, a řekněme, že jsme zvolili přístup face-to-face rozhovor (tazatel se ptá respondenta) se záznamem do papírového archu – dotazníku, pak po provedení všech rozhovorů máme před sebou „hromadu dotazníků“. V zásadě máme dvě možnosti, jak s tímto datovým materiálem naložit a jak jej dále analyzovat: datovou matici (v elektronické podobě) si nevytvoříme a tak k analýze můžeme použít pouze metodu „čárkování“ (případně neustálého přeskupování na hromádky podle třídících znaků), k čemuž nám prakticky stačí tužka a papír případně kalkulačka (lepší je Excel či jiný tabulkový procesor). Touto možností se dále zabývat nebudeme, jednak protože je nespolehlivá a může být při vícenásobném třídění pekelně úmorná a také „data“ vlastně neexistují, není je možné sdílet, zálohovat a tedy ani archivovat.

Druhou cestou, kterou se určitě vydáme, je pořídit ze zápisů v dotaznících elektronický záznam dat do *datové matice*.⁸ Ta má nejčastěji podobu, kterou ukazuje následující obrázek, kde ve sloupcích jsou proměnné a v řádcích případy, v našem případě respondenti. Ale mohly by to být také například různé organizace, proměnné ve sloupcích by pak představovaly kupříkladu jejich příjmy a výdaje za různé oblasti, počty klientů atd. Pokud máte data z jednoduchého výzkumu s využitím jejich sběru pomocí dotazníku, pak jeden datový řádek představuje jednoduše jeden dotazník, tedy jednoho respondenta. Datová struktura ale může být složitější, a také ve výzkumu organizací často bývá. Někdy totiž v datech máme individuální případy (úroveň 1) sloučené do určitých přirozených klastrů (úroveň 2), které jsou v matici upořádané vždy pod sebou. Například provádíme výzkum zaměstnanců (1), kteří jsou z různých poboček firmy (2), analyzovat pak můžeme jedince – zaměstnance i organizační jednotky jako celky mezi sebou ale také obojí navzájem (o tomto uspořádání dat podrobněji v kapitole Úroveň měření, analytická jednotka a volba designu výzkumu, kde máme jednoduchý příklad takovéto víceúrovňové datové matice).

Výhoda záznamu dat do matice v elektronickém formátu spočívá v tom, že je lze jednoduše dále upravovat (transformovat proměnné, například slučovat hodnoty nebo vytvářet znaky nové na základě kombinací jiných původních znaků) a také úsporně archivovat a zálohovat.

⁸ Tím úmyslně pomímám mnohem přívětivější situaci, kdy záznam dotazníku probíhá pomocí nějakého elektronického způsobu zápisu, např. při vyplňování on-line dotazníku samotným respondentem, díky němuž datová matice vzniká víceméně automaticky (popravdě někdy méně než více..., tím mám na mysli různé problémy se způsobem záznamu a konverzí formátu).

Obrázek 1. Datová matice (2-way data: případy x proměnné)

Datová matice

	A	B	C	D	E	F	G	H	I	J
1	ID	pohlaví	ot1	ot2	ot3	ot4a	ot4b	ot4c	ot4d	ot5_vek
2	1	muž	1	0	1	1	2	2	2	45
3	2	muž	3	1	2	3	1	2	1	38
4	3	muž	1	0	2	2	2	1	2	54
5	4	žena	1	0	3	3	3	3	2	18
6	5	žena	1	0	2	2	1	2	2	23
7	6	žena	1	0	1	1	1	1	3	21
8	7	žena	2	1	4	3	2	3	2	25
9	8	žena	3	1	1	2	2	2	1	30
10	9	žena	3	1	4	2	3	2	1	43
11	10	žena	3	1	3	2	3	2	3	21
12	11	žena	3	1	2	1	2	2	1	24
13	12	žena	3	1	1	1	3	1	1	29
14										
15										

Prázdnou datovou matici si vytvoříme před samotným záznamem dat,⁹ kdy si nejprve do sloupců dopředu připravíme názvy proměnných (v některých programech dokonce můžeme i rozsah a popisky hodnot), poté již do řádku budeme postupně zapisovat údaje za jednotlivé případy, v našem případě tedy výpovědi dotázaných. Jeden řádek většinou obsahuje jeden dotazník/výpověď (ale možné jsou i jiné varianty), zatímco sloupečky odpovídají jednotlivým otázkám v dotazníku (i když tak jednoduché to nemusí být, pokud například používáte otázky s vícenásobnými odpověďmi, pak pro záznam jedné otázky budete potřebovat více znaků, tj. sloupečků). Tolik pokud jde o původní „hrubá“ data, v nich ale často v dalších krocích vytváříme nové proměnné, případně transformujeme hodnoty těch primárních („z dotazníku“), takže finální datový soubor pak může obsahovat výrazně více proměnných, než bylo původních otázek v dotazníku. S tím souvisí také to, na jaké úrovni proměnné měříme, tj. jak pořizujeme data (např. za organizační celky může jít o statistiky z výročních zpráv, zatímco uvnitř těchto celků/skupin můžeme dále provádět individuální rozhovory se zaměstnanci, za organizační celky ale můžeme některá data/proměnné také agregovat z individuálních výpovědí) a na jaké úrovni pak data analyzujeme (o tom více v kapitole Úrovně měření, analytická jednotka a design výzkumu). K vytvoření datové matice nám může posloužit v podstatě jakýkoliv tabulkový procesor jako např. Excel (popravdě pro záznam dat stačí i obyčejný textový editor), lepší je ale využít některý ze specializovaných statistických programů pro analýzu dat, např. SPSS/ PSCP, STATA, R, Statistica a dal.¹⁰

⁹ Dříve se tomu říkalo „děrování“, protože kdysi se datový záznam dotazníku pořizoval na děrné štítky, datová matice tak vlastně nebyla, fyzicky existoval pouze balík děrných štítků.

¹⁰ Doporučuji záznam ve formátu programu SPSS (soubory *.sav), jednak proto, že jde o jeden z nejrozšířenějších formátů a dá se převádět na formáty jiných programů a také proto, že vedle standardní

Zda bude údaj – hodnota znaku zaznamenán v podobě čísla nebo slova zaleží hlavně na úrovni měření – typu znaku (o tom více v další části), přesto vždy preferujeme co nejvíce znaků, tj. jejich hodnot zaznamenat pomocí čísel. Zatímco v případě znaků kardinálních, jako je například věk, automaticky zaznamenáme odpovídající číslo (ostatně tyto znaky označujeme také jako „číselné“), tak složitější to může být u znaků nominálních (ty mají hodnoty na úrovni slov). Pokud má nějaká otázka přijatelný počet kategorií odpovědí, tyto kategorie očíslováme a do datové matice zapíšeme jen dané číslo, s tím, že si uchováme tzv. kódovací klíč, kde máme napsáno, jaká cifra odpovídá které odpovědi (většina statistických programů pak dokonce umí k zaznamenaným číslům v datech přiřazovat ve výstupech z analýz odpovídající slovní popisky). Jasně je to v případě tzv. uzavřených otázek (např. u pohlaví můžeme kódovat žena=1 muž =2), pokud máme otázku s otevřenou odpovědí můžeme si dopředu (či postupně během zaznamenávání dat) vytvořit *kódovací klíč* (kde sloučíme opakující se podobné odpovědi) a podle něj zaznamenávat jen číslice.

komerční verze SPSS máte k dispozici zjednodušenou verzi v podobě freeware programu PSPP, v němž můžete data nejen zaznamenat ale také dále analyzovat.

Znaky, jejich typy a role v hypotézách

Jestli na něčem kvantitativní výzkum (KV) stojí, tak to jsou právě proměnné neboli znaky. Ostatně i proto se KV někdy říká „variable orientated approach“, tedy výzkumný přístup založený na proměnných. Možná lépe řečeno: „stojící a padající“ na proměnných tedy mj. limitech jejich měření. V principu v KV hledáme vztahy mezi proměnnými. Tedy pomineme-li, že také můžeme, je-li náš cíl výhradně deskriptivní, pouze měřit hodnoty resp. rozptýl hodnot jednotlivých proměnných samostatně bez hledání vztahů mezi nimi (i když i zde zřejmě uplatníme třídění dat alespoň 2. stupně, např. nás nebude zajímat jen celková míra spokojenosti zaměstnanců, ale také to, zda jsou spokojenější zaměstnanci muži nebo ženy, což už je ale právě sledování vztahu mezi dvěma znaky).

Připomeňme ještě, že proměnnou/znakem rozumíme symbolickou reprezentaci obecné vlastnosti či stavů nějakého jevu nebo objektu a to na určité úrovni abstrakce.¹¹ Jednotlivým vlastnostem/stavům pak v empirickém výzkumu přiřazujeme hodnoty znaku. Tyto hodnoty se mezi odlišnými případy (třeba respondenty) mohou různit, například věk nebo pohlaví. U proměnných rozlišujeme různé typy podle toho, jak se k sobě navzájem mají jejich hodnoty a jak tyto hodnoty můžeme empiricky zaznamenat.

Typy proměnných podle možnosti úrovně měření hodnot

Znaky rozlišujeme podle toho, jak lze rozlišit resp. uspořádat jejich hodnoty (viz obrázek 2).

Nominální: hodnoty (kategorie) znaku jsou rovnocenné (na úrovni jmen), např.: pohlaví, jména, typ rodiny, barva vlasů, obor práce.

Podle počtu hodnot nominální znaky někdy rozlišujeme na *dichotomické* (ty mají jen dvě hodnoty, např. nemocný/zdravý) a nebo *vícekategoriální* (např. bydliště podle kraje ČR).

Ordinální (pořadové): hodnoty lze seřadit do hierarchie, tudíž se lze ptát, která je „vyšší/nížší“, „slabší/silnější“ apod., ale ne o kolik. Např.: míra spokojenosti, stupeň souhlasu (často jde o tzv. Likertovské škály).

Nominální a ordinální¹² označujeme jako **kvalitativní** nebo také **kategoriální**.

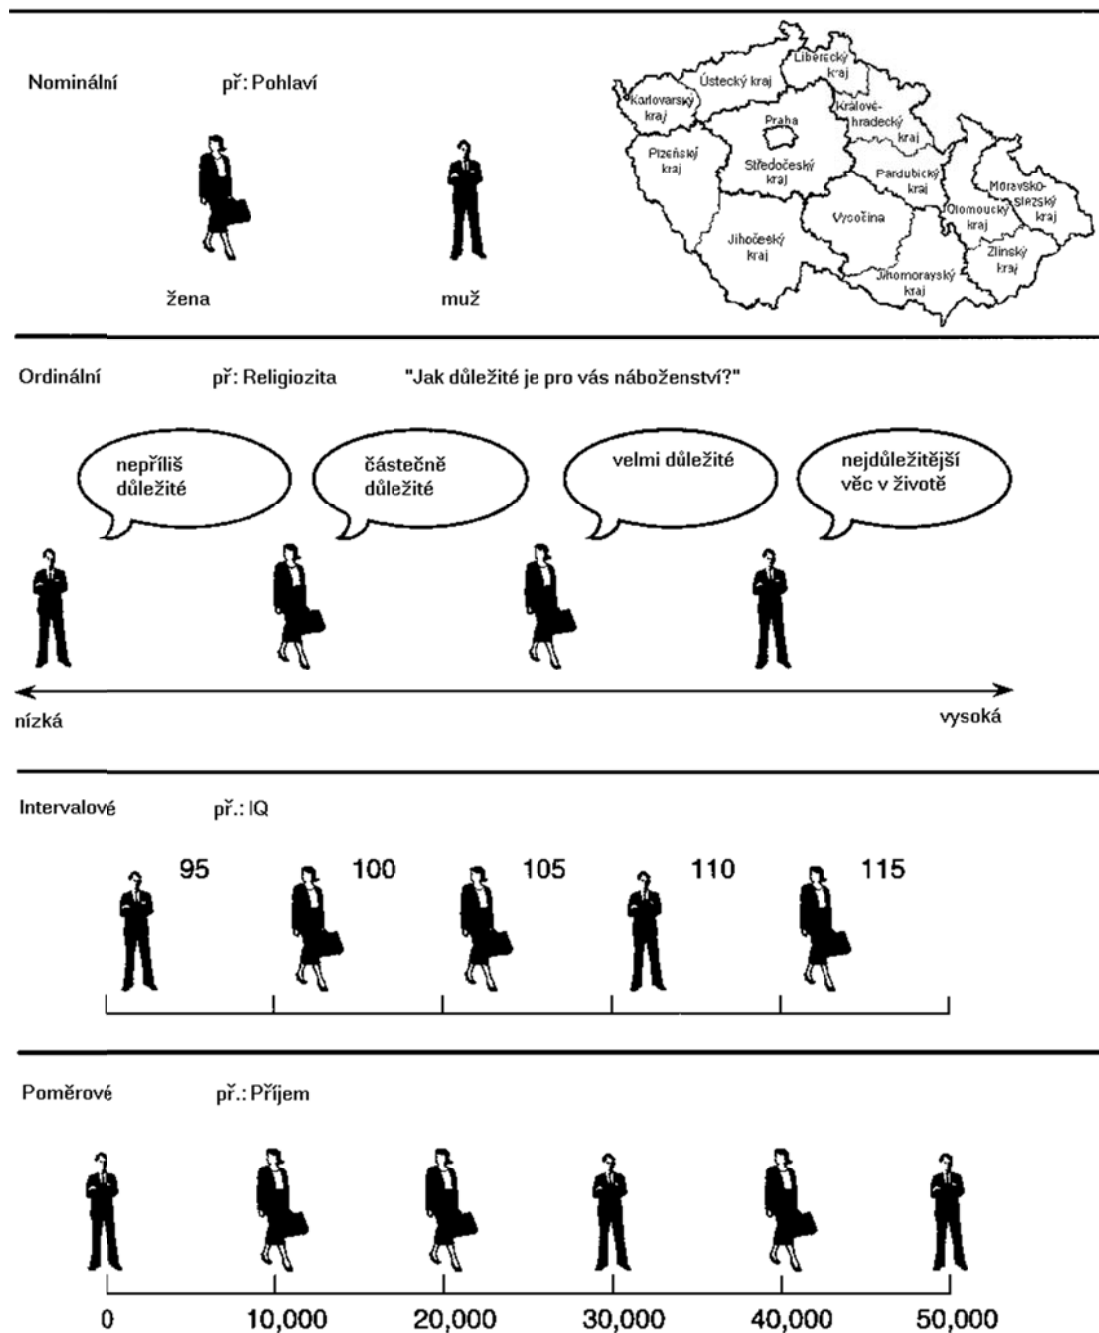
Kardinální – číselné (numerické): obecně platí, že lze určit vzdálenosti mezi hodnotami, které jsou vyjádřitelné pomocí čísla. Např.: věk, příjem, počet dětí. Dále je dělíme na:

a) Intervalové (rozdílové): obsahový smysl má rozdíl mezi hodnotami ale nikoliv podíl;
b) Poměrové u hodnot lze rozlišit nejen větší/menší ale také o kolik (násobky nebo podíly), mají přirozený počátek.

¹¹ Znak můžeme chápat jako množinu symbolů, kdy „jde o odraz vlastnosti jako celku – na rozdíl od odrazu dílčího stavu vlastnosti“. [Řehák 1972: 3] Dodejme ještě, že „k dané vlastnosti může existovat i více znaků. Mohou mít stejný obsah – jednotlivé hodnoty mají stejný význam, mohou se ale i významově lišit ...“. [tamtéž]

¹² Pokud mají menší počet hodnot, řekněme do 15 kategorií a jsme si jisti jejich důslednou hierarchií a přibližnou ekvivalencí vzdáleností mezi nimi.

Obrázek 2. Typy proměnných dle úrovně měření jejich hodnot



Zdroj: adaptováno podle [Babbie 1995: 137]

Metaforická pomůcka pro zapamatování: nominální znak má hodnoty v podobě „slov“, ordinální v podobě „abecedy“ a teprve numerický v podobě „čísel“.

Z hlediska úrovně měření a následně operací v analýze dat jsou na tom nejlépe znaky číselné (kardinální), protože nám poskytují nejvíce informací. Platí, že hodnoty číselných znaků lze

převést (rekódovat) na „nižší“ úroveň, tj. na ordinální případně nominální.¹³ Podobně ordinální lze převést na nominální (či spíše jejich hodnoty považovat při interpretaci výsledků za nominální – neuspořádané). Obráceně to nejde. Úrovně měření – typ znaku pak bezprostředně ovlivňuje, jakým způsobem budeme moci hodnoty znaků analyzovat, tj. v explorační analýze, jaké střední hodnoty budeme moci použít (základní statistiky). Základní přehled středních hodnot, tj. „jednoho čísla, pomocí něž můžeme velmi, velmi zjednodušeně vyjádřit „nejtypičtější“ hodnotu za všechny případy/pozorování“, tedy jakési „těžiště“ hodnot v datech pro danou proměnnou), uvádí tabulka 1. A nezapomeňte ale, že samotná střední hodnota – průměr toho moc neříká, proto vždy ji doplňujeme o nějakou míru variability hodnot v datech, tj. rozptylu, pro průměr to je většinou směrodatná odchylka.

Tabulka 1. Použitelné míry středních hodnot (statistiky) pro typy proměnných podle úrovně měření

		modus	medián	arit. průměr
Nominální	(např. pohlaví)	●	-	-
Ordinální	(např. míra souhlasu 1–4)	●	●	●*
Číselné	(např. věk)	●	●	●

* Průměr můžeme s opatrností použít, pouze pokud ordinální proměnná má větší počet hierarchicky uspořádaných hodnot (řekněme minimálně 5) a navíc jejich rozložení je alespoň symetrické, ideálně by mělo kopírovat tzv. normální rozložení (Gaussova křivka), ale správně bychom pro ordinální znaky měli používat medián.

Ještě poznámka: ve vaší datové matici budou pravděpodobně znaky a to včetně těch nominálních (slovních) zaznamenány většinou jako čísla. Znamená to, že i když je proměnná nominální, např. pohlaví, která má hodnoty – kategorie „muž“ a „žena“ (případně ještě např. „nezjištěno“), tak v datové matici nebudou přímo tato slovní pojmenování hodnot, ale pouze jednoduše čísla a vy musíte vědět, že např. 1 = žena, 2 = muž. Tedy pokud nepoužíváte Excel nebo jiný tabulkový procesor, ale spíše nějaký statistický program (např. SPSS, PSPP, STATA, R), které krom hodnot znaků (tedy toho co jako hodnotu vložíte) zaznamenávají ještě další informaci o hodnotách proměnných – popisky (anglicky label). V Excelu, kde to takto jednoduše nejde, to tak trochu svádí ponechat při zaznamenání u nominálních znaků slova místo čísel, ale věřte mi, pokud s takovými daty budete chtít později pracovat v jiném programu, můžete s tím mít problémy. A hlavně při tomto slovním záznamu mohou vznikat chyby. I proto je výhodné co nejvíce nominálních proměnných (u ordinálních je to s číselným záznamem celkem jednoznačné) zaznamenat v datové matici pomocí čísel, a pořídit si k tomu přehled „číselný záznam=slovní hodnota kategorie“ tzv. codebook.¹⁴ V uvedených

¹³ Kupříkladu z číselné proměnné příjem měřený v Kč vytvoříme ordinální příjmové skupiny (např. dle tzv. kvartilů – rovnoměrně zastoupených kategorií) a ty dále můžeme sloučit na dichotomii např. „podprůměr“ vs. „nadprůměr“, což je vlastně nominální znak).

¹⁴ Jednoduchý codebook si vytvoříte tak, že si „datové“ hodnoty v číslech napíšete k příslušným kategoriím – odpovédím rovnou do dotazníku (pokud to již z původního označení odpovédí v dotazníku automaticky

statistických programech, se tyto labely dají zadat separátně a vy si pak při zpracování dat u výsledků můžete vybrat, zda se objeví s popisky nebo s číselnými hodnotami znaku. Nejenže takový soubor nezabírá příliš místa na disku, ale hlavně se při tom nechybuje a data se dobře přenáší mezi různými softwary. Dokumentace zápisu hodnot je ale nezbytná.

Role proměnných v hypotézách

K roli proměnných v hypotézách. V zásadě mohou být tři. První situace je, že proměnná je *závislá*, neboli *vysvětlovaná*, to je ten znak jehož varianci v hodnotách chceme vysvětlit (říkejme mu Y), anglicky se takové proměnné někdy říká „outcome“, takže to je výsledek něčeho, ať už jsou to rozdíly a nebo nějaký složitější proces. Logicky druhou rolí znaku musí být proměnná *nezávislá*, tedy *vysvětlující*, anglicky také někdy „predictor“, protože nám pomáhá vysvětlit–předpovědět hodnoty závislé proměnné. Pomocí jejích hodnot se snažíme vysvětlit hodnoty závislé proměnné. Zdůrazňuji, že se ještě nemusí jednat o kauzální vztah, k jeho prokázání či ověření potřebujeme více informací, většinou změřit další proměnné – ty pak mají v analýze roli *kontrolní* a také specifický design měření (viz dále).

Rozlišení nezávislé a závislé proměnné – příklady

Mnoho začínajících výzkumníků tyto pojmy matou. Nejjednodušší způsob, jak si zapamatovat který je který, je že závislá proměnná "závisí" na nezávislé proměnné. Například zkoumáme-li souvislost postoje k interrupci a genderu, tj. zda osoba souhlasí s potraty z jakéhokoli důvodu závisí na tom, zda daná osoba je muž nebo žena. Naopak, zjevně nedává smysl říkat, že to zda je člověk muž nebo žena, závisí na tom, zda souhlasí s potraty.

Mnoho výzkumníků označuje závislou proměnnou za "výsledek" zatímco nezávislou proměnnou za "prediktor". V tomto příkladu je tak prediktorem pohlaví, protože předpovídá výsledek – postoj k interrupci.

Někdy může být obtížné ba dokonce nemožné, abychom určili, zda jedna proměnná je nezávislá a druhá nezávislá. Někdy se totiž proměnné mohou ovlivňovat navzájem. Představte si, že jedna proměnná je přesvědčení, že jíst maso představuje zdravotní riziko (můžeme mít např. čtyři kategorie: rozhodně souhlasím, souhlasím, nesouhlasím, rozhodně nesouhlasím) a druhá proměnná je, zda člověk jí maso nebo ne. Lze říci, že naše přesvědčení ohledně rizika jíst maso je nezávislou proměnnou a naše chování – konzumace masa je závislá proměnná. Znamenalo by to, že to zda jíme maso, nebo ne, závisí na tom, zda si myslíme, že konzumace masa představuje zdravotní riziko. Ale představte si i jinou alternativu. Člověk může přestat jíst maso na základě svého postoje k problematice práv zvířat. Vyhýbání se konzumace masa po několik let vede k tomu, že časem hledáme určité odůvodnění, proč tak (ne)činíme a při tom je možné, že se posílí naše víra, že konzumace

nevyplývá, což je nejlepší i pro spolehlivost při zadávání dat do počítače). Doporučuji určitě provést v elektronické verzi, dobře se sdílí s kolegy, navíc pouze papírová podoba codebooku má tendenci se ztrácet.

masa představuje zdravotní riziko. V takovém případě náš postoj závisí našem předchozím chování.

Neexistuje žádné jednoduché řešení, pokud si nejsme jistí ohledně toho, který znak je závislý a který nezávislý. Někdy to může záviset na časové souslednosti. To, co nastalo jako první bývá nezávislá proměnná. Jindy jsme prostě nuceni konstatovat, že proměnné jsou vzájemně propojeny bez možnosti rozpoznat, která z nich je nezávislá a která je závislá.

Zdroj: [Acock 2014: 124]

Poznámky k operacionalizaci – měření proměnných

Operacionalizaci provádíme v zásadě ve třech úrovních resp. etapách. Tou asi nejhlavnější, nejdůležitější a také asi nejtěžší je fáze během přípravy výzkumu (a jak víme, bezprostředně souvisí s obecnějším vymezením indikátorů tedy konceptualizací). V obecnější rovině souvisí s volbou nástroje a také obecněji s designem výzkumu (na jaké úrovni budu znak měřit, jakým způsobem, pomocí jakého nástroje, bude třeba měření opakované v čase ...?).

Poté co najdeme odpovědi na tyto obecnější otázky, musíme vyřešit, jaká bude konkrétní podoba operacionalizace dané proměnné ve zvoleném nástroji měření. Pokud se zde dále omezíme na metodu sběru dat pomocí dotazníku, pak půjde především o to, jaké otázky budeme klást, tj. na co se budeme ptát z hlediska fenoménu, který chceme měřit a také, jak se budeme ptát či spíše jakou formou se budeme ptát, což souvisí s typem a formátem otázek (baterie otázek, bipolární výroky, projektivní otázka atd.) a koneckonců i s jejich konkrétní formou – formulací (a to včetně grafické podoby).¹⁵

V prvé řadě jde ale o rozhodnutí, zda znak bude měřen *přímo s použitím konceptu*, který lze vymežit *jednoduše pomocí intuice*, což ovšem předpokládá, že význam otázky je univerzální, sdílí ho jak výzkumník–respondent tak všichni potenciální respondenti ve zkoumané populaci (například otázka „máte zájem o službu xy?“ mezi klienty, kteří poskytované služby dobře znají),¹⁶ nebo zda zvolíme vymezení *pomocí postulátu* postaveného na určitých předpokladech, tedy vycházejícího z nějakého složitějšího teoretického rámce (například pokud budeme chtít měřit loajalitu zaměstnanců k organizaci, tak takto složitý koncept nemůže ve výzkumu zachytit jen jedna otázka).¹⁷ Taková situace již vyžaduje vícepoložkové měření (rozuměj více než jednu otázku v dotazníku), z něž budeme v získaných datech

¹⁵ V případě sběru dat s využitím dotazníku je tak operacionalizace obecně „překladem konceptů do dotazníkových otázek“ [Saris, Gallhofer 2007: 6].

¹⁶ To neznamená, že zkoumaný fenomén nemůže mít více dimenzí, tedy že musíme klást jen jednu otázku. Zde jde o to, že u konceptu měřeného pomocí intuice, je shoda mezi tím, co si pod znakem představuje výzkumník a jak je chápán těmi, koho zkoumá, navíc vycházíme z toho, že všichni položené otázce rozumí stejně je jednodimenzionální (univerzální), což ale tak nemusí být(!), proto je dobré během opracionlaizace uvažovat i jiných dimenzích.

¹⁷ Nikdy se neptejte ve smyslu „Jste loajální zaměstnanec?“ Odpovědi dost možná dostanete, ale otázka je nakolik budou reliabilní a hlavně, zda budou vůbec validní (tedy co vlastně budou ve skutečnosti měřit).

teprve v další fázi konstruovat proměnnou jako latentní konstrukt z více přímo měřených proměnných (viz dále). Teprve pak se můžeme věnovat problémům spjatých se slovní a stylistickou formulací otázek, jejich návaznosti (pořadí) a kontextem jejich umístění v dotazníku (např. existuje nebezpečí haló efektu) a volbě konkrétních kategorií odpovědí.

Jak naznačeno, otázka operacionalizace – principu měření – se může objevit ještě i poté, co jsme již data po náročných fázích přípravy a sběru konečně získali. Právě u výše zmíněných složitějších konceptů vymezených pomocí postulátu většinou operacionalizace pokračuje další fází konstrukce syntetických proměnných. To mimochodem také souvisí se zvolenou statistickou metodou konstrukce latentních znaků (musíme se rozhodnout, zda nám bude stačit prostý součet jednotlivých položek např. z baterie výroků nebo znalostního testu do sumačního indexu, zohledníme při tom jejich odlišnou váhu dimenzionalitu měřeného konceptu a/nebo uplatníme složitější model zohledňující i chyby měření?). Někdy jde také o složitější kombinace nebo rekódování hodnot při splnění určitých podmínek. Například když měříme socioekonomický status (SES) nebo prestiž profese, tak se nejprve v dotazníku ptáme na to, jakou profesi či povolání dotázaný vykonává (či v minulosti vykonával). Slovní popis – název profese zaznamenaný pomocí otevřené otázky nejprve zakódujeme, tj. převedeme na nějakou číselnou klasifikaci povolání (např. ISCO či KZAM) a tu následně rekódujeme na hodnoty statusu SES či prestiže typické pro tu kterou profesi. V datech tak máme tři proměnné: název profese (slovo), číselný kód profese, přičemž v obou případech jde o nominální znak, a SES (číselný index, který je kardinálním znakem).

Asi tušíte, že během všech výše popsaných etap procesu operacionalizace nám hrozí nebezpečí, že pokud nástroj měření připravíme „nekvalitně“, může to vést ke zkreslení naměřených hodnot a to jak z hlediska reliability (spolehlivosti měření) tak především z hlediska validity (obsahové platnosti). Navíc přípravná fáze výzkumu – námi vytvořený „recept na měření proměnných“ musí být jednoznačný, srozumitelný a detailně zdokumentovaný. Tak aby čtenář výsledků založených na našich datech rychle pochopil, co a jak jsme měřili a mohl si tento proces zkontrolovat (podrobit kritice), případně dokonce výzkum zopakovat, pokud by si chtěl naše výsledky ověřit nebo na ně navázat. V kvantitativním výzkumu platí, že to jak znaky operacionalizujete, tj. jak je změříte, to vám zásadním způsobem určí možnost další práce s daty a pochopitelně v konečném důsledku limituje výsledky, ke kterým dojdete. Pokud totiž ve výzkumu typu „survey“ s využitím sběru dat pomocí dotazníkového šetření znaky nevhodně operacionalizuje resp. „špatně“ změříte, nejde chybu již napravit, protože se již nelze vrátit zpět do terénu. Zkrátka vyjádřeno jednoduše anglickým rčením: „Garabage in, Garbage out“. Sem pochopitelně patří i problém opomenutých – neměřených proměnných, které ale měly v modelu být zahrnuty či alespoň kontrolovány a také klíčová otázka reprezentativity dat z vašeho výběrového souboru vůči zkoumané populaci.

A nezapomeňte: *postupujeme od výzkumné otázky k formulaci otázek v dotazníku, nikdy ne naopak!*

Nakonec ještě jedna poznámka k měření proměnných. Proměnná, kterou budeme využívat v analýze k zodpovězení našich výzkumných otázek může být v datové matici získána v zásadě dvěma způsoby, což souvisí s výše uvedeným rozdělením měření konceptů v dotazníkových šetřeních pomocí intuice (přímo) a postulátů–konstruktů (více položek sloučených do latentní proměnné). Buď je *měřena přímo během procesu sběru dat*, nebo jde o *syntetickou proměnnou*, která vznikne až dodatečně v datech pomocí nějaké transformace (nejčastěji vzájemnou kombinací hodnot několika proměnných).

V prvním případě hodnoty znaku v datech pak přímo odpovídají naměřeným hodnotám v terénu, například během dotazování. Nejtypičtějším příkladem je situace, kdy jsou hodnoty znaku v datové matici odvozeny rovnou z kategorizovaných odpovědí v dotazníku (nejčastěji jde o číselné kódy odpovědí na uzavřené otázky či dodatečně zakódované odpovědi na otázky otevřené).¹⁸ Ale abychom nezůstali jen u dotazníkového šetření, získat hodnoty takovýchto přímo měřených znaků můžeme také třeba pozorováním (například provádíme pozorování v prostředí sociální služby, kdy zaznamenáváme, kolika klientů se každý sociální pracovník během pracovního dne zeptal „jak se mu/jí dnes daří ...“, tato čísla se pak objeví v datové matici, v níž pro každého pracovníka máme jeden datový řádek). V principu tedy „co jsme měřili“ bude bezprostředně v datech.

Přímo naměřené znaky ale také nemusí být předmětem analýzy samy o sobě, ale mohou sloužit ke konstrukci nové syntetické proměnné. Jde tedy o součást námi zvolené operacionalizace. Například míru samostatnosti klienta budeme měřit jako sumační index, který vznikne na základě součtu jednotlivých odpovědí z položkové baterie otázek (tj. sečteme do nové proměnné kolik věcí je schopen si sám obstarat).

Do přímo měřených proměnných bychom ještě mohli zařadit situaci, kdy původní bezprostředně naměřené hodnoty dále nějakým způsobem pouze redukuje, tedy když u jedné proměnné rekódujeme hodnoty do nových, nejčastěji sloučením určitých hodnot do menšího počtu (kupříkladu se ptáme na délku praxe v letech, a následně tuto kardinální–číselnou proměnnou převedeme na kategorie vyjadřující rozsah, např. 0–2 roky, 2–4 roky, atd.). Ale jsou i jiné možnosti, například může nastat zcela obrácená situace, když se v dotazníku ptáme na délku praxe pomocí kategorií s rozpětím let a ty pak nahradíme jedním číslem – střední hodnotou.¹⁹ Vznikne tak jakási kvazi–číselná proměnná, mějte však vždy na paměti, jak byla původně měřena, například spočítat pro ní průměr není vždy spolehlivé (originální měření si vždy v datech raději ponecháme, když už pro nic jiného tak alespoň pro kontrolu, jak nový znak vznikl). Viz také kapitolu Úrovně měření, analytická jednotka a design výzkumu.

¹⁸ Pochopitelně, že určitá transformace je někdy nutná, například odpovědi v dotazníku jsou označeny písmeny: a) b) c), které ale v datové matici z praktických důvodů zaznamenáme jako čísla 1, 2, 3. Také často data–hodnoty proměnných nejprve tzv. čistíme, tj. rekódujeme či odstraňujeme nelogické či neodpovídající hodnoty (např. odpovědi „nevím“ kódujeme speciálním číslem, třeba 9, a následně je vyloučíme z některých analýz).

¹⁹ Nabízené odpovědi v dotazníku a) „0–2 roky“ nahradíme číslem „1“, b) „2 až 4 roky“ nahradíme „3“, atd. Ačkoliv jsme tak znak měřený na úrovni

Jak intuitivně na ověření platnosti hypotézy (druhého řádu) – příklady

Pro jistotu si nejprve připomeňme, že rozlišujeme hypotézy prvního a druhého (či obecněji vyššího) řádu. Záleží na tom, kolika proměnných se bude hypotéza týkat. Hypotéza „prvního řádu“ tedy znamená, že uvažujeme rozložení hodnot jen jednoho znaku. Příkladem budiž třeba výrok: „Většina klientů chráněného bydlení by chtěla využívat službu osobní asistence“. Jenomže, k čemu nám takový výrok je? Jak jsme přišli na to, že to má být právě většina? A jak takovou většinu budeme definovat? (je výsledek 54 % již očekávanou „většinou“ nebo ještě ne?) Takovými hypotézami se proto nebudeme dále zabývat, jsou většinou *de facto* jen deskripcí za celou populaci, a tudíž nejsou příliš produktivní. Raději se jich vyvarujte. Ostatně jenom kvůli nim asi výzkum dělat nebudeme, to si raději zformulujeme smysluplné ryze explanatorní dílčí výzkumné otázky. Například, kolik klientů chráněného bydlení bych chtělo využívat službu osobní asistence? Povšimněte si, že v analýze zde stále půjde o třídění dat prvního stupně, tedy pouze za jednu proměnnou, ale smysluplnost takto motivovaného výzkumu je teď určitě mnohem vyšší. Jistě vás ale v tuto chvíli napadají ještě zajímavější otázky, kvůli kterým by stálo zato realizovat výzkum. Kupříkladu, kolik najdeme zájemců o službu osobní asistence mezi klienty, kteří se vyznačují větší samostatností (přesněji, jaký bude jejich relativní podíl)? Jinými slovy, naše výzkumná otázka může znít: „existuje vztah mezi zájmem o službu osobní asistence a mírou samostatnosti klientů chráněného bydlení?“. Tímto se již dostáváme k hypotéze druhého řádu, tedy výroku o očekávaném vztahu dvou proměnných, přesněji řečeno o vzájemné provázanosti jejich hodnot.

Vybaveni znalostí základních pojmů, ukažme si postup ověřování platnosti hypotézy na dvou jednoduchých příkladech. V prvním představíme, jaké základní varianty postupů v analýze máme k dispozici, pokud chceme ověřit platnost hypotézy druhého řádu, tj. o vztahu hodnot dvou znaků (třeba X a Y). Podotýkám, že půjde o intuitivní „nestatistický“ přístup. V druhém příkladu naznačíme, proč je důležité o hypotézách druhého řádu přemýšlet v širších souvislostech, tedy jako o modelu vztahů.

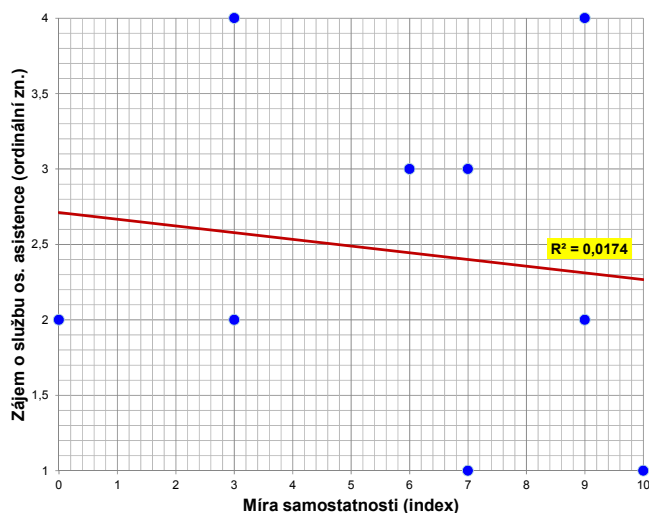
V principu je postup při ověřování hypotéz o vztahu dvou a více proměnných následující. Nejprve formulujeme hypotézu (ta obsahuje dva znaky, které musíme operacionalizovat, to zde ale přeskočíme). Poté musíme zvolit populaci, na kterou chceme výsledky zobecnit a provést z ní případně výběr reprezentativního vzorku, v němž na sobě nezávisle, to jest zcela odděleně, naměříme hodnoty znaků X a Y (to jakým způsobem shromažďujeme data, zde ponechme stranou).²⁰ Získané údaje vložíme do datové matice a pomocí níže uvedených

²⁰ Někdy data vůbec nemusíme sami sbírat (tj. pozorovat subjekty, dotazovat respondenty anebo třeba kódovat texty). Jsou situace, kdy data vhodné k zodpovězení naší výzkumné otázky resp. ověření hypotézy v nějaké podobě již existují (možná si je ale budeme muset nějak upravit). Například může jít o dostupné informace

jednoduchých postupů zjistíme, zda se hodnoty znaků X a Y vzájemně nějak mění, tedy jestli mezi proměnnými existuje nějaká souvislost, jakou má povahu a jak je silná. Věcně posoudíme trend tohoto vztahu i jeho intenzitu a na základě toho se rozhodneme, zda platnost hypotézy potvrdíme či vyvrátíme. Podotýkám, že musí jít o hromadný proces vyznačující se tak určitou zobecnitelností (výsledkem pak může být například predikce pro podobné případy v budoucnosti nebo v podobné populaci) a tudíž shromažďujeme hromadná data o mnoha případech (jedincích), nikoliv o jednom či několika málo případech.

Pokud jde o **hypotézy druhého řádu**, tj. předpoklady o vztahu mezi hodnotami dvou a více proměnných, pak se vlastně snažíme vysvětlit varianci, tj. rozptyl hodnot závislého znaku pomocí hodnot nezávislého znaku/ů. K tomu nám slouží v analýze tzv. třídění dat druhého stupně. Zní to složitě, ale je to jednoduché. Ukážeme si to na příkladu vztahu zájmu o službu osobní asistence a míry samostatnosti klientů chráněného bydlení (viz prezentace 4b). V zásadě mohou nastat tři situace dvourozměrného třídění dat:

(1) buď jsou *obě proměnné kardinální (číselné)*, pak používáme nejčastěji a nejjednodušeji korelační analýzu – vztah mezi znaky pak vyjádříme jen jedním číslem – koeficientem korelace; pozor nejběžněji používaný základní korelační koeficient (tzv. Pearsonův) ukazuje jen na vztahy víceméně lineární (tedy přímé či nepřímé úměry), mj. i proto si vždy před výpočtem korelace vztah dvou proměnných zobrazte graficky pomocí např. bodového X-Y grafu (scatter plot), protože ne vše je v „sociálním životě vyjádřitelné přímou úměrou“;



(2) *jedna proměnná – závislá je kardinální (případně ordinální) a druhá (vysvětlující) kategorická (tedy nominální nebo ordinální)*, zde je situace asi nejsrozumitelnější, protože

v databázi klientů. Podobné je to, pokud využíváme již existující data z výzkumu provedeného někým jiným a my na nich provádíme tzv. sekundární analýzu. Ostatně vždy než začnete připravovat výzkum založený na dotazování lidí (rozhovory, dotazníky), tak se nejprve poohlédněte po alternativních zdrojích dat, protože nezapomínejte, že dotazovat se lidí, byť by to bylo třeba jakoby odosobněně po internetu v online dotazníku, neznamená nic jiného než, že budete tyto lidi otravovat a okrádat je o drahocenný čas. Navíc ve svém důsledku jen budete tzv. „zamořovat“ terén zbytečným výzkumem, takže lidé se pak nebudou chtít nějakého užitečného a nezbytného výzkumného šetření zúčastnit. A platí, že s rostoucím podílem neochoty účastnit se výzkumných šetření v populaci se bohužel také snižuje reprezentativnost jejich výsledků.

spočítáme aritmetický průměr (nebo medián) pro závislou proměnnou samostatně v jednotlivých kategoriích (podskupinách) podle nezávislé proměnné a vzájemně je porovnáme, budou-li zhruba stejné, pak souvislost mezi těmito dvěma znaky nejspíše²¹ v našich datech není;

	Samostatnost (hodnota indexu 1-10)		
Zájem o službu os. asistence	Průměr	Směrodatná odchylka (rozptyl)	Celkem (absolutní četnost)
Zájem	6,6	xx	xx
Nezájem	4,2	xx	xx
Celkový průměr	5,1	xx	xx

(3) oba znaky jsou kategorizované (tj. nominální nebo ordinální), tady použijeme podobný postup jako v případě 2, ale počítáme a interpretujeme procenta (neboli pravděpodobnosti (násobené stem)), a to tak že porovnáme podíly hodnot závislého znaku v podskupinách nezávislého znaku (ty jsou vlastně podmnožiny tvořící vždy 100 %), a opět jsou-li relativní podíly závislé proměnné ve skupinách nezávislé proměnné přibližně stejné, znamená to, že souvislost mezi znaky (nejspíše) není.

	NEZÁVISLÁ – vysvětlující proměnná			
ZÁVISLÁ – vysvětlovaná proměnná	Samostatnost			Celkem (absolutní četnost)
	Zájem o službu os. asistence	Nizká	Vysoká	
Zájem		41 %	66 %	xx
Nezájem		59 %	34 %	xx
Celkový součet		100 %	100 %	xx

Zdůrazněme, že označení závislá (Y) a nezávislá (X) ještě samo o osobě neznamena kauzální působení, jde jen o označení znaku, u něž budeme vysvětlovat proměnlivost hodnot (Y) pomocí měnicích se hodnot znaku jiného (X), platí tedy vztah oboustranný $X \leftrightarrow Y$. Pokud bychom chtěli prokázat skutečný vliv $X \rightarrow Y$, pak bychom museli v analýze dokázat ještě další skutečnosti (o tom si povíme dále v kapitole o možnostech a limitech empirického prokázání kauzálních vztahů).

Nyní příklad druhý, kde si ukážeme, že uvažovat ve vztahu mezi dvěma proměnnými pouze tyto dva znaky někdy nestačí. A to zejména tehdy, kdy nám nejde jen o deskripci, nýbrž chceme pochopit sociální fenomény v širších souvislostech, cíl našeho výzkumu je tedy

²¹ Povšimněte si, že slovo „nejspíše“ (neboli „pravděpodobně“) zde vyjadřuje určitou míru nejistoty závěrů pro naše data. Vztahy mohou být někdy pěkně komplikované, například to že v bivariátním vztahu nenajdeme souvislost a ona ve skutečnosti existuje, může být způsobeno tím, že se projeví pouze za určitých podmínek. A to jsme opět u té třetí – intervenující proměnné (Z), která, může vztahy mezi X a Y někdy také potlačovat (nepravá nesouvislost). To se ale děje spíše jen ve výjimečných případech. Jinou otázkou může být, zda se vztah mezi proměnnými projeví při námi použité úrovni měření, v analýze například použijeme rekódovanou proměnnou (tj. spojíme určité hodnoty), přitom to, jak rekódujeme původní hodnoty na nové může ovlivnit to, že žádný vztah nenajdeme. (A to pomímám tu možnost, že vztah mezi jevy ve skutečnosti existuje, ale mi jej nenaměříme, protože máme špatný měřicí nástroj. To je pak otázka validity a částečně i reliability měření.)

explanatorní (nejnáročnějším vrcholem této výzkumné činnosti je pak ověření fungování kauzálních mechanismů). Řekněme, že zkoumáme příjmové/platové rozdíly a jejich možné příčiny. Závislá proměnná (Y) bude příjem a nezávislá proměnná (X) je věk pracovníka. Můžeme formulovat hypotézu, že příjem se zvyšuje s věkem. K jejímu ověření musíme nejprve zvolit populaci, na kterou chceme výsledky zobecnit, provést z ní případný výběr reprezentativního vzorku pracovníků a naměřit na sobě nezávisle hodnotu znaku X (věk) a hodnoty znaku Y (příjem). Získané údaje vložíme do datové matice a pomocí jednoho z výše uvedených jednoduchých postupů zjistíme, zda se hodnoty příjmu a věku vzájemně nějak mění. Věcně posoudíme trend tohoto vztahu i jeho intenzitu a na základě toho se rozhodneme, zda platnost hypotézy potvrdíme či vyvrátíme. Tady bychom mohli skončit. Ostatně deskriptivní cíl je tímto splněn. Sociální realita však není tak jednoduchá a proto by se nám mohlo stát, že bychom buď zjišťovali úplné triviality, které dávno každý zná, anebo co je ještě horší, mohli bychom se dopouštět chybných závěrů (a při tom se tvářit bůhví jak chytře, protože přeci máme dokonale kvalitní data a na nich provedenou skvělou analýzu). Pravda je, že (zatím) skvěle provedenou analýzu rozhodně nemáme.²² Abychom se vyvarovali nezáživným popisům resp. chybným/nedokonalým závěrům musíme vzít v úvahu ještě další možné vlivy, což znamená zahrnout do analýzy další znak či znaky. Ten se zde tak ocitne v třetí roli, kterou mohou proměnné hrát v hypotézách či v modelu vztahů. Pracovně je nazvěme *kontrolní znak/y* (a označme jej třeba Z). Jeho konkrétní funkce může být různá (o tom si ještě povíme dále). V zásadě ale jde o to, že Z nějakým způsobem vztah mezi X a Y mění: zesiluje nebo naopak oslabuje, nebo to může být také tak, že X je jen jakousi „zástěrkou“ pro skutečný vztah—vliv Z na Y (nicméně variant vzájemného působení mezi třemi a více proměnnými může být mnohem více).

Vraťme se do našeho příkladu, ukážeme si v něm situaci označovanou jako *nepravá souvislost* [podrobně viz Disman 1993: 219-223]. Přestavme si, že v našem výzkumu chceme zkoumat téma příjmové diskriminace z hlediska věku. Bude nám k tomu stačit naměřený vztah dvou proměnných Y a X, kdy v datech pozorujeme, že příjem s věkem roste? Asi tušíte, že nikoliv. Proto vezměme ještě jinou vlastnost, tj. proměnnou Z – pracovní zkušenost měřenou v letech praxe. I zde můžeme očekávat korelaci s příjmem (Y), dokonce pravděpodobně o dost vyšší než tomu bylo u věku (X). A co se asi stane, pokud bychom nyní spočítali korelaci tj. souvislost mezi příjmem a věkem při „kontrolě“ vlivu délky praxe v oboru (Z)?²³ Zní to složitě, ale představte si to tak, že proměnnou praxe (X) rozdělíte například do tří kategorií (rekódujete kardinální proměnnou na kategorie pod/nad/průměrná délka) a že korelace mezi věkem a příjmem nyní spočítáte pro každou z těchto skupin pracovníků zvlášť

²² Možná ale máme kvalitní, rozuměj reprezentativní, reliabilní a validní výběrová data. Problém „kvality“ dat v tomto příkladu ponechme stranou.

²³ Takovou korelaci s kontrolou další proměnné/ých, tj. „očištěnou“ o její/jejich vliv skutečně můžeme spočítat, jde o tzv. parciální korelaci. Původní bivariátní korelaci mezi X a Y v této souvislosti říkáme korelace nultého řádu (anglicky zero-order). Jednodušším postupem odhalení interakce znaku X s hodnotami znaku Z je ale výše uvedený výpočet podmíněných korelačních koeficientů v rozdělených hodnotách (podle kategorií, případně do intervalů—hladin hodnot, pokud jde o číselnou proměnnou) třetího kontrolního znaku. Dodávám, že nejde o ekvivalentní metody.

(dodávám, že existuje mnohem elegantnější řešení pomocí tzv. parciální korelace, ale na tom bychom to tak jednoduše nepochopili). Pravděpodobně dojde k tomu, že nyní jednotlivé korelační koeficienty budou menší, než byl jeden celkový za všechny skupiny dle délky praxe dohromady. Souvislost mezi X a Y zde zkrátka oslabí (někdy dokonce i zmizí) jakmile kontrolujeme vliv faktoru v pozadí mající vliv jak na Y (zde příjem) tak i X (délku praxe v oboru), což obojí bezpochyby věk ovlivňuje. Pokud by k oslabení vztahu nedošlo, pak by to v našem příkladu znamenalo, že vliv věku na příjem je pravděpodobně přímý a není jen funkcí, tedy jakýmsi „měřeným zástupcem“, délky praxe (jinými slovy možná by se v takovém případě mohlo jednat i o onu věkovou diskriminaci, ale k takovému závěru bychom potřebovali ještě mnohem více informací a další analýzy). Řekněme tedy, že korelace v podskupinách dle délky praxe jen do určité míry oslabí. To může znamenat, že část vlivu spadá na věk a část na praxi (i když v tomto konkrétním příkladu to ale tak úplně jednoduché není, protože délka praxe je logicky na věku funkčně prakticky závislá; navíc vlivy věku a délky praxe mohou jít dost možná i tak trochu paralelně „proti sobě“: starší pracovníci mají delší praxi, kterou zaměstnavatel oceňuje vyšším platem, ale také (někteří) starší lidé mohou být diskriminováni nižším příjmem protože, že je na ně zaměstnavatelem stereotypně nahlíženo jako na „neperspektivní“). Právě to slovíčko „někteří“ (starší lidé) je hrozně důležité, cílem analýzy zaměřené na věkovou diskriminaci by totiž dále bylo zjistit, o jakou skupinu či skupiny „starších“ zaměstnanců jde.

Ukázali jsme si tedy, že zůstaneme-li jen u dvojrozměrného vztahu mezi X a Y (neměřili bychom a posléze do analýzy nezahrnuli délku praxe a pravděpodobně také mnoho dalších proměnných), mohli bychom se, pokud bychom tedy v našem výzkumu zkoumali právě téma příjmové diskriminace z hlediska věku, dopustit chybného závěru. Zamyslete se u tohoto příkladu nad modelem vztahů: jaké různé varianty můžeme najít ve vztahu příjmu a věku? Jaké další charakteristiky (proměnné) bychom potřebovali měřit (tj. mít v datech), abychom vztah mezi příjmem a věkem adekvátně popsali?

Co z toho plyne pro přípravnou fázi výzkumu, kterou se zabýváme v KMVP? Jednoznačně poučení, že *nestačí měřit jen ty vlastnosti – proměnné, které máme v našich základních hypotézách, ale že již v přípravné fázi výzkumu(!) musíme přemýšlet o možných jiných vlivech, potenciálně ovlivňujících/zkreslujících vztahy které zkoumáme*. Protože, pokud je nezměříme ve fázi sběru dat, tak je již nikdy nezměříme.

S tím nám pomůže **model vztahů**, což je vlastně jakási soustava hypotéz, která zahrnuje jak ty naše základní hypotézy, o které nám jde především, tak i hypotézy s kontrolními znaky. Zároveň to je takový plán měření – co vše budeme muset měřit; také do toho může vstupovat kontext, což je jednak *faktor času* (když se něco má měnit) a/nebo také *organizační/prostorové uspořádání*, kdy dopředu víme, že z hlediska zkoumaného jevu je oprávněné se domnívat, že tento organizační kontext bude námi zkoumaný jev, tedy závislou proměnnou (ale i nezávislé proměnné) ovlivňovat. Tím může být například členění organizace na určité jednotky, kupříkladu oddělení. Ideální je vztahy v hypotézách si graficky zobrazit.

Detailní postup na příkladu „Zájem o službu osobní asistence podle samostatnosti klientů chráněného bydlení“ najdete v prezentaci [Příklad postupu ověření platnosti hypotézy - základní možnosti třídění dat 2. stupně](http://kmvp.wz.cz/KMVP_hypoteza_overeni_priklad.ppt) <http://kmvp.wz.cz/KMVP_hypoteza_overeni_priklad.ppt>

Když jsou znaky tři (či více) a možnosti–limity empirického prokázání kauzálních vztahů

Obecně se v sociálních vědách považuje za empiricky prokázaný kauzální vztah dvou proměnných (tj. příčinnost ve vztahu $X \rightarrow Y$), pokud jsou splněna tato tři kritéria: 1. mezi proměnnými X a Y existuje empirická korelace/asociace (souběžné změny hodnot u obou proměnných); 2. příčina časově předchází následek (hodnoty znaku X vznikly dříve než hodnoty znaku Y) a 3. zároveň platí, že vztah X a Y není výsledkem působení jiné třetí proměnné (Z) či dalších proměnných.

A jak může tato „třetí“ proměnná vstupovat do vztahu dvou klíčových–fokálních proměnných, které máme například v jednoduché hypotéze?

První možností je, že nám zamlžuje vztah (anglicky confounding factor), výsledkem je tzv. *falešná korelace*. Naměřený vztah mezi Y a X je ve skutečnosti především vztahem mezi Y a Z (tj. jakási příčina X v pozadí). [příklad viz Disman 1993: 219-222]. V praxi se ani tak nesetkáváme s čistě falešnou korelací, tj. situací kdy po té co kontrolujeme vliv třetího znaku, vztah mezi Y a X zcela zmizí, ale spíše s částečně zkresleným vztahem (a nebo také modifikovaným, viz dále). Například ve výzkumu zjistíme korelaci mezi výší příjmu a spokojeností se životem, tato korelace nicméně bude o dost slabší, pokud budeme kontrolovat vliv vzdělání, které ovlivňuje jak výši příjmu, tak i životní spokojenost (zde ale přesto určitá část variance v naměřených hodnotách spokojenosti může jít, navíc nad efekt vzdělání, na vrub právě příjmu).

Ačkoliv situace mezi třemi proměnnými může být složitější (a pokud je jich více tak mnohem komplexnější) a odpovídající analýza patří spíše do pokročilejších učebnic statistiky, přesto je třeba pochopit alespoň základy vzájemných možných vztahů mezi více proměnnými. Smyslem není naučit se princip analýzy, daleko zásadnějším důvodem je, že o těchto vztazích musíme přemýšlet již v přípravné fázi výzkumu, protože analyzovat můžeme jen to, co máme v datech, tj. co jsme naměřili.

TOTO NEBUDE U ZKOUŠKY. Třetí proměnná může být i ve významově důležité roli, o jejíž zhodnocení nám od počátku jde. Může být v roli mediátoru a nebo moderátoru.

Mediátor (M) je takový znak (zastupující vlastnost či jev), jak naznačuje název, skrze který je do určité míry vztah mezi X a Y zprostředkován (mediován). Jde vlastně o kauzální řetězec, kde hraje roli i časová posloupnost. X působí jak na M, tak na M a část vlivu X na Y se tak uplatňuje skrze M. Typický příklad z oblasti mezigenerační mobility: profesní–socioekonomický status otce (nezávislá–vysvětlující proměnná X) působí na profesní–socioekonomický status potomka (závislá– vysvětlovaná proměnná Y) z větší části skrze vzdělání potomka (mediátor M). To ale neznamená, že se zde neprojevuje i přímý vliv SES

otce na SES potomka (např. díky inspiraci rodičovským povoláním, ekonomickým a sociálním zázemím rodiny nebo také sociálními kontakty rodičů). *Moderátor* naproti tomu vztah mezi Y a X jen modifikuje, například Zatímco moderátorová proměnná upřesňuje, za jakých podmínek se určitý vliv ($X \rightarrow Y$) projeví (zesiluje/zeslabuje), v analýze jde tedy o modelování vzájemné interakce, tak mediátorová proměnná nám může ukázat, jakým mechanismem a proč se tento efekt projeví, a tudíž nám jde o modelování kauzality (a proto bychom zde ideálně potřebovali longitudinální data). Mimochodem moderátorová proměnná vůbec nemusí být korelovaná jak s nezávislou tak závislou proměnnou, často jde o určitý sociodemografický/prostorový kontext (jako třeba pohlaví, věk, region; např. vztah mezi příjmem a spokojeností může být jiný u žen a u mužů nebo může třeba klesat s věkem).

Cíle výzkumu

Cíle výzkumu mohou být v zásadě tři. *Explorace* představuje průzkum jevu či také populace, o kterém/é toho zatím moc nevíme a možná zvažujeme, zda bychom v budoucnu nepovedli podrobnější výzkum. V rámci exploračně orientovaného výzkumu také můžeme vyvíjet a ověřovat nástroje měření.

Při *deskripci* usilujeme o to, co nejpřesněji popsat stav jevu skrze závěry učiněné na reprezentativním vzorku z populace, důležitá je tedy reprezentativita výběrového souboru.

Explanatorní cíle jsou nejnáročnější, neboť se snažíme jevy nejen popsat, ale také je vysvětlit, tj. hledáme odpovědi na otázku „jak“ a „proč?“. Chceme pochopit, jak resp. za jakých podmínek k něčemu dochází. Nežrídka je tak naším cílem predikce, tj. na základě poznatků z výzkumu provedeném ve výběrovém souboru odhadnout, jak se v celé populaci někdo zachová nebo jakého nabude stavu/vlastnosti, za předpokladu že má určité vlastnosti (například na základě některých vlastností klientů dokážeme odhadnout, jak úspěšný dopad na určitý typ klienta bude mít program naší intervence). Speciálním účelem je pak zhodnocení efektů – *evaluace* nějakého intervenčního programu, ta většinou vyžaduje přípravu ještě náročnějšího výzkumného designu (zohlednění role času, podchycení dalších intervenujících faktorů, náhodné přiřazování do intervenční a kontrolní skupiny atd.).

Cíle deskripce a explanace se pochopitelně mohou vzájemně prolínat. Vyžadují bezpodmínečně, aby data byla reprezentativní za populaci (a pochopitelně také, aby měření bylo reliabilní a validní). Při realizaci těchto cílů výzkumu (zejména při deskripci a explanaci) budeme v analýze používat třídění dat druhého stupně, tj. hledat zda a jak spolu souvisí hodnoty dvou (a více) znaků. Proto i při pouhé deskripci rozlišujeme znaky závislé (tříděné) a nezávislé (třídící) a přestože je také často nazýváme „vysvětlované“ a „vysvětlující“ nemáme v tomto případě automaticky na mysli jejich vzájemnou kauzální vazbu (k tomu musíme vyzkoumat a posoudit ještě více informací, viz předchozí kapitolu věnovanou možnostem ověření kauzálního vztahu).

Úrovně měření, analytická jednotka a volba designu výzkumu

Měřit hodnoty proměnných můžeme u *individuů* (nejčastěji lidé, např. zaměstnanci, klienti) anebo také celých *organizací / skupení* (např. oddělení v nemocnici, pobočky organizace, obce). Někdy *individuální data agregujeme* a dále analyzujeme za organizační jednotky, např. průměrná spokojenost s vedoucím za jednotlivé pobočky (pak porovnáváme pobočky nikoliv variabilitu uvnitř nich). Někdy naopak *měříme přímo na úrovni organizací*, např. dotazník pro manažery vypovídající „ne za sebe“ ale „za organizaci“, nebo máme k dispozici nějaká statistická data (třeba jakési „výkaznictví“, např. o počtech klientů atp.).

Rozlišujeme přitom *úroveň, na jaké měříme* a na jaké pak *data analyzujeme*. Nejčastěji měříme na individuální (1) úrovni, kterou ovšem lze doplnit o data za vyšší (2) úroveň. Někdy také měříme data na individuální úrovni, ale analyzujeme jen na úrovni agregované, což ale může vést k problému opomenutí vnitřní variance, proto ideální je víceúrovňový design měření i analýzy. Ukažme si to na příkladu pracovníků nebo klientů v odlišných organizacích: úroveň 1. *jedinci* (např. zaměstnanci nebo klienti) a úroveň 2. *organizace*: a) kontextová data měřená přímo za zařízení poskytující péči (např. stal řízení, počet a typ klientů, rozpočty organizačních jednotek atp.) a b) agregovaná data z dat měřených individuálně uvnitř organizací na úrovni 1 (např. průměrný věk, průměrná spokojenost anebo loajalita k firmě, průměrná soběstačnost klientů). V obrázku 3 je jednoduchý příklad takovýchto víceúrovňových dat z hypotetického výzkumu.

Obrázek 3. Víceúrovňová data: organizace (1), organizační jednotky (2) a zaměstnanci (3)

organizace	org_jednotka	zamestnanci	styl_rizeni	poc_zamest	spokojenost	X_spok/org_jedn	X_spok/organz	
1	1	1	1	participativni	9	4	3,7	
		1	2	participativni	9	2		
		1	3	participativni	9	5		
	2	2	1	1	direktivni	7	1	1,5
			2	2	direktivni	7	2	
			2	2	direktivni	7	2	
2	1	1	1	demokraticky	19	2	2,8	
		1	2	demokraticky	19	4		
		1	3	demokraticky	19	3		
		1	4	demokraticky	19	2		
3	1	1	1	participativni	5	4	4,5	
		1	2	participativni	5	5		
	2	2	1	1	demokraticky	10	2	1,7
			2	2	demokraticky	10	2	
			2	2	demokraticky	10	2	
			2	3	demokraticky	10	1	

Poznámka: hodnoty pro spokojenost: 1=velmi nespokojen až 5=velmi spokojen

V příkladu máme zaměstnance tří organizací/firem, které jsou dále členěny na organizační jednotky, např. pobočky. Informace za pobočky jsme získali jednak z oficiálních materiálů organizace – počet zaměstnanců a dále z pozorování jednotlivých vedoucích, kdy vždy pět nezávislých expertů vypracovalo hodnocení jejich stylu řízení (do dat vstupuje typ, u nějž mezi experty panuje největší shoda). Vedle toho jsme provedli dotazníkové šetření na náhodném výběru 14 zaměstnanců z celkového počtu 50 (ideální by zde bylo zvolit

stratifikovaný náhodný výběr, kde strata budou odpovídat právě pobočkám, a pochopitelně také zvětšit výběrový soubor zaměstnanců případně i organizací).²⁴ Dodejme ještě, že design zvoleného výzkumu je zde průřezový (crosssectional; viz následující kapitolu), tedy že měření provádíme pouze v jednom časovém okamžiku.

Uvědomte si, že poslední dva sloupce – průměrná spokojenost v pobočkách a v organizacích – zde nepředstavují výsledek analýzy (i když by pochopitelně také mohly a jistě je takto budeme interpretovat), nýbrž vytváří nová *kontextuální data*, tj. agregovanou úroveň spokojenosti jednak za pobočky jednak za organizace. Budeme je totiž dále využívat v analýzách. Předpokládáme například, že míra spokojenosti toho kterého zaměstnance je dána nejen jeho individuálními vlastnostmi/vlivy (třeba pracovní pozice nebo věk), ale také dost možná i kontextem, ve kterém se pohybuje – pomineme-li styl řízení na pobočce – kupříkladu atmosférou na pracovišti a tu může představovat třeba právě kumulovaná spokojenost ostatních kolegů na pobočce (zde jednoduše zprůměrovaná z individuálních výpovědí za pobočky).

V příkladu tak vidíme, že organizační jednotky se z hlediska průměrné spokojenosti zaměstnanců poměrně dost liší. Zajímavé ale je, že mezi celými organizacemi je spokojenost stejná (průměr vždy 2,8). Spokojenost zaměstnanců lze obecně, tj. pro všechny zkoumané organizace (či odpovídající populaci organizací, pokud bychom zde měli jen reprezentativní vzorek organizací), dost možná vysvětlit pomocí odlišného stylu řízení v dané organizační jednotce: vidíme, že spokojenější jsou na pobočkách, kde panuje participativní styl řízení. Zde tedy analyzujeme data na úrovni poboček (styl řízení měřený za pobočku a agregovanou průměrnou spokojenost za pobočku). Nicméně pozor, tento závěr platí jen jako deskriptivní. Bez dalších informací a analýz nelze totiž jednoduše tvrdit, že „určitý styl řízení vede ke spokojenosti“! Koneckonců hledat souvislost individuální spokojenosti zaměstnanců můžete kupříkladu i s velikostí pracoviště, tj. počtem zaměstnanců (opět na druhé úrovni poboček). A zde v našem případě platí, že spokojenost klesá s velikostí pobočky.²⁵ My ale mimochodem víme, že menší pobočky jsou řízeny direktivně. Co je tedy příčinou: velikost nebo styl řízení? (A vůbec můžeme si být jistí, že skutečná příčina spokojenosti není v něčem jiném?) Takže i v tomto jednoduchém případě vidíte, že to s prokázáním vlivu není tak jednoduché.

Struktura dat a zvolené úrovně měření tak ovlivňují, jaké výzkumné otázky si můžeme klást. Mimo jiné do hry může také vstoupit *role času*, například pokud zkoumáme nějakou změnu; navíc pro posouzení kauzálních vlivů či evaluaci programu/změny potřebujeme ještě tzv. kontrolní skupinu, ovšem všemi vlastnostmi srovnatelnou(!) s cílovou populací, u níž změna neproběhla.

²⁴ Volba strat by nám jednak zaručila, že budou zastoupeny všechny pobočky a dále by umožnila zajistit „dostatečný“ počet vybraných zaměstnanců za pobočku a tím zvýšit jejich vzájemnou reprezentativitu (tedy snížit směrodatnou chybu v datech). Pokud bychom totiž zvolili strata jako neproporční (tedy neodpovídající poměrově velikosti počtu zaměstnanců za pobočku), mohli bychom pak počet vybraných zaměstnanců u malých poboček navýšit, tak aby za pobočku byl vždy dostatečný počet případů.

²⁵ Korelace pro agregovaná data za pobočky (tedy nyní jen 5 případů – datových řádků) je negativní $r = -0,21$.

Rozlišení úrovní měření a analytických jednotek je důležité, zejména při výzkumu organizací (například zkoumáme-li fenomény jako leadership, organizační kultura či loajalita zaměstnanců). Proto se na začátku přípravy výzkumu ptejte, bude se cíl nebo jen třeba konkrétní dílčí hypotéza týkat vlastností případů – jedinců (v dotazníkovém šetření tedy respondentů) a/nebo (také) vyšší úrovně např. organizace? Pokud půjde o vyšší úroveň, bude to v podobě dodatečné agregace dat za jedince (např. pracovníci různých oddělení) anebo budete přímo měřit/získávat údaje za dané organizační celky (např. odlišnosti v managementem nastaveném přístupu ke klientům v různých odděleních)? Můžeme v datech očekávat varianci hodnot, nebo hrozí „logický výpadek“ v potenciálním rozptylu některých znaků (tj. situace, kdy všechny případy mají z povahy věci u jednoho znaku stejné hodnoty)? Jinými slovy, bude „co s čím“ porovnávat? Například zkoumáme-li obecné souvislosti stylu řízení a spokojenosti zaměstnanců, bude v našich datech zastoupena dostatečná variabilita–odlišnost stylů řízení v jedné organizaci či dokonce v celém souboru organizací? Pokud by tomu tak nebylo, pak si nelze vůbec klást výzkumné otázky (resp. ověřovat hypotézy) druhého řádu o vztahu hodnot dvou znaků (a to díky logickému výpadku, kdy by jedna proměnná měla ve všech případech/datových řádcích pouze fixní–neměnné hodnoty).²⁶ Odpovědi na tyto otázky jsou východiskem pro přípravu designu studie.

²⁶ K nulové varianci hodnot znaku v získaných datech pochopitelně může dojít i z jiných důvodů. Buď proto, že dopředu nemáme ani elementární představu o možných hodnotách proměnné a výzkumný nástroj nastavíme neadekvátně (skutečné hodnoty zkoumaného fenoménu nám pak ve výsledku splynou jen v jedné naměřené hodnotě znaku), nebo sice nějaký rozptyl hodnot naměříme, ten ale bude extrémně malý (takže prakticky nulový) anebo víceméně umělý, protože jsme měřili nevalidně a nereliabilně (například odpovědi na „hloupou“ nikomu nic neříkající otázku v dotazníku budou prakticky nahodilé, navíc v čase nestabilní). V těchto případech sice nejde o předem daný „logický výpadek“ variability hodnot znaku, nicméně i tak jde o výzkumníkovu chybu – ten má vždy připravit tak kvalitní nástroj měření, aby variabilitu zkoumaného fenoménu (tj. v reálném světě) dokázal alespoň částečně podchytit a „kvalitně“ (= validně a reliabilně) změřit.

Výzkumný design – typy uspořádání výzkumu

Možná se to nezdá, ale právě design, ve smyslu uspořádání výzkumné studie (zejména jde o segmentaci populace a roli času), je pro možnost zodpovězení některých výzkumných otázek zcela rozhodující. V zásadě je lze rozdělit na dvě hlavní skupiny podle cílů výzkumu [Oppenheim 1992]. Do první patří *deskriptivní design*, kdy nám jde víceméně o „počítací“ výzkum ve smyslu statistického sčítání, a jak patrně z názvu, ten umí řešit jen deskriptivní – popisné cíle výzkumu. Pokud je cíl našeho výzkumu *explanatorní*, tj. usilujeme o odhalení kauzálních mechanismů resp. chceme zhodnotit nějakou změnu či intervenci, pak je situace složitější a máme na výběr z vícero konkrétních výzkumných designů, obecně je můžeme označit jako analytický (vztahový) design. Ten v mnohém využívá logiku laboratorního experimentu, v němž jedině máme tu výhodu, že můžeme manipulovat hodnotu intervenující (nezávislé) proměnné.

Uvedme zde v krátkosti jen ty nejzákladnější formy uspořádání takové výběrového šetření:

1. Průřezové (*cross-sectional*)

a) *jednorázové* (výzkum provádíme pouze v jednom časovém bodě. Jde o nejčastěji používaný design, ten má ale výrazné limity, pokud jde o explanaci procesů.

b) *opakované* (longitudinální) na odlišných případech – výběrech z populace. Umožňuje mapovat trendy vývoje, nikoliv ale odhalovat kauzální mechanismy.

2. *Longitudinální - panelové* (tj. opakované na stejných případech). Výrazně zlepšuje možnosti vysvětlovat procesy.

3. *Relační-síťové (sociometrické)*. Jde o poněkud jinou oblast, design se týká spíše metody sběru dat a jejich analýzy (v zásadě zde můžeme uplatňovat všechny výše uvedené designy).

4. *Případová studie* – není reprezentativní za celou populaci, může ale jít více do hloubky problému, v zásadě jde o doménu kvalitativního výzkumu.

Mezi další speciální designy výzkumu patří například *faktoriální, kvazi-experimentální* nebo *intervenční* s cílem evaluace (před a po realizovaném intervenčním programu). Kromě posledně zmíněného, se kterým se většinou kombinuje, stojí z hlediska našeho studijního oboru za pozornost design *víceskupinový umožňující párové srovnání případů z experimentální skupiny, kde jsme provedli nějakou intervenci a kontrolní skupiny* (matched samples). Podmínkou je zde, aby kontrolní skupina byla srovnatelná s experimentální, jde tedy o to vybalancovat tyto skupiny především z hlediska charakteristik, které mohou ovlivňovat efekt, který ověřujeme – výsledek intervenčního programu. Rozdílné vlastnosti těchto skupin (selekce) totiž mohou způsobit rozdíly ve výsledku, které pak můžeme mylně připisovat efektu evaluovaného intervenčního programu. Problémem je, že některé charakteristiky, které tyto rozdíly způsobují nelze jednoduše měřit – jsou nepozorované (tam, kde je lze měřit, můžeme později provést pomocí speciálních statistických metod

jakousi korekci selekce do experimentální a kontrolní skupiny), jde kupříkladu o motivaci, která může vést jak k vyšší pravděpodobnosti účasti v programu, tak ale i nezávisle na něm k lepším výsledkům ve sféře, ve které intervenci provádíme. Zde je proto důležité, aby rozdělení účastníků do experimentální a kontrolní skupiny bylo provedeno náhodně, což ne vždy je jednoduše realizovatelné (více se o evaluačním výzkumu dočtete v [Hora, Suchanec, Žižlavský 2014]).

Nezapomeňte, že design – zvolená strategie výzkumu (research design) rozhoduje o možnostech cílů a zobecnění výsledků výzkumu. Pokud nám stačí popis v jednom časovém bodě (cílem je deskripce), pak si vystačíme s jednorázovým průřezovým designem (cross-sectional). Pokud chceme zkoumat změnu, pak potřebujeme buď opakovaný průřezový design (repeated cross-sectional), to pro sledování trendů anebo panelovou studii, ta ale musí být reprezentativní s ohledem na daný časový řez – dobu (je-li provedena jen v jedné věkové kohortě, pak bude reprezentativní jen za ní). Chceme-li odhalit kauzální vztahy, pak musíme realizovat buď panelovou studii nebo (kvazi-)experiment (případně lze použít i cross-sectional data s retrospektivním zjišťováním, ale zde musíme důsledně aplikovat techniky elaborace v survey analysis, což ale platí i o analýze dat z předchozích uspořádání). Je-li naším cílem evaluace – zhodnocení intervence (například intervenčního programu pro klienty nebo zavedení nějaké organizační změny), pak budeme potřebovat nejen design s měřením „před“ a „po“ intervenci (a to nejlépe vícekrát opakovaně v delším časovém horizontu), ale také nejspíše zavedení rozdělení na experimentální/intervenovanou a kontrolní skupinu. A konečně chceme-li uplatnit strukturně relační pohled, např. na vztahy na pracovišti, pak použijeme relační–síťový design (social network analysis). Uvedené příklady nejsou vyčerpávající a hlavně – zahrnují pouze kvantitativní větev výzkumu. Nezapomeňte, že existuje i výzkum kvalitativní, jenž využívá také různé designy (základní přehled najdete třeba v [Švaříček, Šed'ová a kol. 2007: kap. 4]).

Pravidla a doporučení pro přípravu výzkumu (zatím jen vybraná)

Vždy si na počátku kladte otázky (nejprve může jít o výzkumné otázky spíše dílčí, které vám pomohou s objasněním obecnějšího problému, který chcete zkoumat). Hypotézy (nabízí nám na tyto otázky předem odpověď, kterou budeme výzkumem ověřovat), jsou až sekundární (víceméně zajišťují především buď technickou stránku věci – jak se nechat při přípravě šetření vést, anebo jsou úzce spjaty s teorií a jejím ověřováním, tj. především akademickým výzkumem). Také centrální – obecnou výzkumnou otázku, která to vše zastřeší, můžete zformulovat, až budete mít promyšlené konkrétní dílčí otázky. Začínajte tedy raději od konkrétního (co nesamozřejmého byste se chtěli dozvědět, co o problematice ještě nevíme/nezjistil někdo jiný) než abstraktního a příliš širokého problému, v němž se pak snadno ztratíte.

Před tvorbou dotazníku (a vlastně celého výzkumu) si udělejte seznam proměnných, které chcete a potřebujete měřit. Nikdy nezačínajte dotazníkem jako takovým! To samozřejmě neznamená, že před tvorbou vlastního dotazníku nebudete číst jiné dotazníky. Inspirujte se jimi, ale v této fázi si vždy dotazníkové otázky překládejte do konceptů resp. konkrétních proměnných. Nenechte se okouzlit „pěknými otázkami“. V této fázi totiž musíte myslet výhradně v proměnných (a jak je budete měřit, to bude až další krok, v němž už půjde mj. o konkrétní znění otázek). Dobrá rada: vyznačte si ve výzkumných otázkách/ hypotézách všechny znaky, které budete potřebovat k jejich ověřování a po té si ze seznamu proměnných vytvořte (zatím prázdnou) datovou matici. Teprve pak začnete vytvářet dotazník. A když už ho budete mít, tak ho zpátky „přeložte“ do seznamu proměnných (například tím, že si k otázkám v dotazníku dopíšete koncepty/proměnné, co mají měřit). Budete nyní schopni s tímto inventářem proměnných zodpovědět vaše výzkumné otázky?

Vyvarujte se výzkumu, který by zjišťoval triviální, dávno známe věci. Pokud budete postupovat podle metodologických učebnic, můžete jakoukoliv triviálnost zabalit do hávu sofistikované vědeckosti, tak že to celé bude navenek vypadat jako „úžasné zajímavý výzkum“, i když reálně naše poznání nikam neposune. Vždy se snažte hlavní výzkumnou otázku/y (hypotézy) formulovat jednoduše a obhájit, proč se tímhle máte zabývat a to před obyčejnými lidmi. Ptejte se sama sebe – přispěl/a bych na takovýto výzkum ze svých peněz? Bylo by to k něčemu? Zkrátka nedělejte „výzkum pro výzkum“. Jen protože vám někdo řekl, že máte „použít výzkum“, automaticky nemusí znamenat, že právě výzkum v podobě dotazníkového šetření bude smysluplnou činností.

Ostatně vždy než začnete připravovat výzkum založený na dotazování lidí (rozhovory, dotazníky), tak se nejprve poohlédněte po alternativních zdrojích dat. Nezapomínejte, že dotazovat se lidí, byť by to bylo třeba jen na chvíli a zdánlivě neškodně – odosobněně po internetu v nějakém kratičkém online dotazníku, neznamená nic jiného než, že je budete otravovat a okrádat je o drahocenný čas. Navíc se ve svém důsledku budete vždy tak trochu podílet na tzv. „zamořování“ terénu (zbytečnými) výzkumy, takže lidé se pak nebudou chtít nějakého užitečného a potřebného výzkumného šetření zúčastnit. A bohužel platí, že s

rostoucím podílem neochoty účastnit se výběrových šetření se také snižuje reprezentativnost jejich výsledků.

Nezapomeňte krom klíčových–fokálních znaků (ty které máte ve výzkumné otázce) měřit i ty, které by mohly očekávané vztahy zkreslovat či modifikovat. Proto si vždy, poté co už máte formulovány základní otázky a hypotézy, sestavte model vztahů, kde jsou hypotézy pojaty komplexně a bereme v úvahu i to, co nás na první pohled jakoby ani nezajímá. A to včetně designu výzkumu (úrovně měření, role času, zdroje dat atd.).

*Důkladně promyslete a připravte design studie. Zejména pak tehdy, kdy zkoumáte populaci, která je členěná do nějakých přirozených shluků či (pod)skupin (ve výzkumu organizací je to skoro vždy) a/nebo váš výzkum není čistě explorační /deskriptivní, ale *máte náročnější cíle jako je zhodnocení změny, např. evaluaci přínosu nějakého programu, či vysvětlení mechanismů určitého jevu, tj. když nás zajímá kauzální působení: příčina → následek*. Prakticky vzato nejde jen o otázku vhodně nastaveného výběru vzorku z populace, kdy vedle určení jeho velikosti (dané mj. úrovní hloubky třídění dat v analýze) zvažujeme také např. jeho případné členění do strat (tj. ptáme se, zda neexistuje z hlediska zkoumaného jevu v populaci nějaká přirozená segmentace, kterou bychom ve výběru měli/mohli případně zohlednit). V první řadě totiž musíme uvažovat o různé úrovni/jednotkách měření resp. analýz. Kladte si otázky jako: Co či koho budou v datech reprezentovat individuální výpovědi, zda je budeme nějak dále agregovat za určité organizační celky; co takto agregovaná data vlastně budou „měřit“ a „za koho/co“ budou vypovídat? Budou tyto vyšší organizační celky zastoupeny dostatečným počtem případů a bude zajištěna jejich reprezentativita ve výběru? Umožní nám získaná data z hlediska zodpovězení výzkumné otázky produktivní a smysluplnou komparaci, tj. co/koho s čím/kým budeme porovnávat (tedy zda vůbec budeme mít „koho/co“ srovnávat). Budeme získaná data dále kombinovat s nějakými jinými datovými zdroji?*

A pokud chcete provést zhodnocení nějaké změny či vlivu intervenčního programu, pak je nezbytné vzít v potaz „roli času“, tj. provést měření přinejmenším před a po změně a také sledovat kontrolní skupinu. Nezapomeňte tedy změřit počáteční stav jevu/vlastnosti, který chcete ovlivňovat, jakož i potenciální vlivy vaší intervenci předcházející či probíhající paralelně (tzv. confounding factors). Ideálně pokud to lze, využijte design náhodného experimentu („randomized experiment“). A nebudou-li participanti evaluační studie, která hodnotí vliv nějakého programu či organizační změny přiřazování do skupiny vystavené vlivu tohoto programu/změny (tj. do experimentální skupiny) a do kontrolní skupiny čistě náhodně, ptejte se dopředu, zda budou tyto skupiny shodné i z hlediska co nejširší palety vlastností. Tyto charakteristiky pro vás představují kontrolní znaky, které když je u obou skupin změříte, což vám pak v analýze alespoň umožní porovnat velikost změny u „co nejvíce si podobných“ případů z kontrolní a experimentální skupiny. Pokud kontrolní skupinu nelze z principiálních důvodů vůbec sestavit, což mnohdy nejde, tak musíte měřit vícekrát a v co nejdelším období před změnou jakož i po ní (tj. jen bezprostředně před a po změně nestačí), dále pochopitelně zohlednit (měřit) zmíněné kontrolní proměnné a také se pokusit najít

nějaký „ideálně typický“ případ(y) „odjinud“, který by vám alespoň částečně kontrolní skupinu nahradil, přesněji řečeno spíše jen ilustrativně dokumentoval, jak se zkoumaný fenomén vyvíjí v „maximálně podobné“ populaci, v níž ovšem žádná změna neprobíhá.

A na závěr jedna užitečná rada z knihy Sedm pravidel pro sociální výzkum od Glenna Firebaugha (2008: kap. 1). Buďte připraveni na to, že vás výsledky výzkumu mohou překvapit. Ty kdo dělají výzkum poprvé, nejčastěji zaskočí, když najdou jen slabé efekty či malé rozdíly, tam kde očekávali, že budou velké. Jenže málokdy najdete hned na počátku své výzkumné praxe tak silné vlivy, jak byste čekali. A i když tak možná budete na začátku z takovýchto výsledků zklamáni, je důležité mít na paměti, že empiricky zjištěný „nulový efekt“ vůbec neznamená „žádný objev“. Naopak. Platí, že každý výsledek je zjištění. A nalezení „nulového vlivu“, tedy dodejme, je-li robustní a přesvědčivé, může být mnohdy zajímavější, než objevení „velkého vlivu“, a to zejména tehdy, kdy běžně přijímaný názor tvrdí, že onen (velký) vliv existuje. Ostatně je to právě nejistota ohledně možných výsledků, kvůli které to celé podstupujete. Vždyť jaký by dávalo smysl dělat výzkum, kdybyste už dopředu znali odpovědi na vaše výzkumné otázky?

Literatura

Doporučené čtení

- Disman, M. 1993. *Jak se vyrábí sociologická znalost*. Praha: Karolinum.
- Babbie, E. 1995. *The Practice of social Research*. 7th Edition. Belmont: Wadsworth (kapitoly 1–6, 8, 10, 13, 21).
- Bryman, A. 2008. *Social research methods*. Oxford: Oxford University Press. (kapitoly 2–10).
- Kapr, J., Z. Šafář. 1969. *Sociologie nebo zdravý rozum? Praxe sociologického průzkumu*. Praha: Mladá fronta.
- Dillman, D. 2006. Handout „*Writing Questions*“. kurz Sociology 525 „Survey Practicum“.
- De Vaus., D. A. 1986. *Surveys in social research*. London: Allen & Unwin.

Použité reference

- Acock, A. C. 2014. *A gentle introduction to Stata. 4th ed.* College Station, Tex: Stata Press.
- Firebaugh, G. 2008. *Seven Rules for Social Research*. Princeton: Princeton University Press.
- Hora, O., M. Suchanec, M. Žižlavský. 2014. *Evaluační výzkum*. Brno: Masarykova univerzita.
- Oppenheim, A. N. 1992. *Questionnaire design, interviewing and attitude measurement. New Edition*. London and New York: Continuum.
- Řehák, J., B. Řeháková. 1986. *Analýza kategorizovaných dat v sociologii*. Praha: Academia.
Kapitulu 2. *Proměnné a jejich typy* najdete na
http://metodykv.wz.cz/Rehakovi1986_k1a2_Promenne_typy_Jednotky_soubory.pdf
- Saris, W. E., I. N. Gallhofer. 2007. *Design, evaluation, and analysis of questionnaires for survey research*. Hoboken, New Jersey: John Wiley & Sons, Inc.
- Švaříček, Klára Šedová a kol. 2007. *Kvalitativní výzkum v pedagogických vědách: pravidla hry*. Praha Portál.
Ukázku z knihy najdete na
http://obchod.portal.cz/Foto/sample/eknihy/pdf/kvalitativni_vyzkum_v_pedagogickych_vedach.pdf