METODIKA HODNOCENÍ PODPORY R&D Z HLEDISKA KONKURENCESCHOPNOSTI PODPOŘENÝCH SUBJEKTŮ

Autorský kolektiv:

doc. Ing. Jan Čadil, Ph.D.

doc. Ing. Jakub Fischer, Ph.D.

doc. Ing. Pavel Mertlík, CSc.

Ing. Ludmila Petkovová, Ph.D.

Ing. David Hartman, Ph.D.

Ing. Marek Beránek, Ph.D.

Ing. Karel Mirošník

Tato metodika je výsledkem řešení výzkumného projektu č. TB94TACR001 pod názvem Hodnocení efektivity programů veřejné podpory ve výzkumu a vývoji programu BETA Technologické agentury ČR.

Praha, únor 2016

Obsah

1 Cíle a popis metodiky ... 2

2 Teoretické základy kontrafaktuální analýzy. ... 4

2.1 Podstata a podmínky kontrafaktuální analýzy ... 4

2.2 Postup CIE ... 5

3 Metody CIE ... 8

3.1 Náhodný výběr (randomizace) ... 8

3.2 Propensity score matching (PSM) ... 10

3.3 Double difference ... 15

3.4 Instrumentální proměnné ... 17

3.5 Regression Discontinuity ... 19

4 Závěry a doporučení ... 22

4.1 Doporučení pro Technologickou agenturu ČR ... 22

5 Praktická ukázka uplatnění metodiky CIE pro Technologickou agenturu ČR ... 24

5.1 Definice cíle programu, časový rámec ... 24

5.2 Definice výstupních indikátorů ... 24

5.3 Definice metody, volba covariates a struktury modelu. ... 25

5.4 Sběr dat, analýza datového zdroje a redefinice modelu. ... 26

5.5 Implementace CIE – náhodný výběr ... 28

5.6 Implementace CIE – PSM ... 34

5.6.1 Konkurenceschopnost ... 34

5.6.2 Růst přidané hodnoty ... 37

5.6.3 Změna přidané hodnoty na korunu osobních nákladů ... 39

5.6.4 Inovační aktivita ... 40

5.6.5 Změna patentů (inovační aktivita) ... 43

5.7 Double difference (Difference in difference) ... 45

5.8 Shrnutí praktické ukázky využití metodiky ... 47

Literatura ... 48

Publikace autorů předcházející metodice ... 50

1 Cíle a popis metodiky

Podpora výzkumných a rozvojových aktivit (dále VaV) by měla v současnosti být, zejména s ohledem na proběhlou ekonomickou krizi, jedním z hlavních nástrojů stimulujících růst vyspělých ekonomik (OECD 2012). Nejdůležitější motivací podpory VaV je jeho předpokládaný pozitivní dopad na konkurenceschopnost a růst způsobený vyšší inovativnosti dané ekonomiky. V současné době je podle statistik Eurostatu průměrný podíl celkových výdajů na VaV v EU28 2,03 % (EU19 2,11) (Eurostat 2014) a zároveň průměrná výše výdajů na VaV v soukromému sektoru činí 1,3 % HDP[1] (1,35 EU19) , což je více než 60 %. Z toho je zřejmé, že zásadním investorem v této oblasti je právě soukromý sektor. Problémem soukromých VaV výdajů je nicméně to, že jsou procyklické (Barlevy 2007), tedy v době hospodářského útlumu klesají a tento pokles dále prohlubuje ekonomický propad a oddaluje fázi zotavení. Právě proto řada zemí po roce 2009 začala výrazně podporovat především oblast VaV v soukromém sektoru, například daňovými úlevami nebo i přímou veřejnou podporou. Jak ukazuje kompilativní meta-studie Correa a kol. (2013), je pravděpodobné, že veřejná podpora VaV v soukromém sektoru se projeví nárůstem čistých výdajů (tedy po odečtení podpory) o 0,166 až 0,252 EUR na jedno vynaložené euro, tedy až 25 % navíc ze strany soukromého sektoru.

Výsledný dopad na konkurenceschopnost firem a ekonomický růst je nicméně v řadě případů z hlediska empirie diskutabilní. Je to dáno do značné míry nejen použitými metodami a daty, ale také stavem daného prostředí a nástroji, které byly na podporu VaV použity (Correa at al. 2013). Analýzy by zároveň měly především odpovědět na otázku, jaký efekt měla podpora VaV na zaměstnanost, ekonomický růst a konkurenceschopnost, spíše než na to, kolik prostředků bylo díky veřejné intervenci vynaloženo ze strany soukromého sektoru nebo kolik bylo uplatněno patentů, užitných vzorů, publikací apod. (jde o stávající standardní pojetí inovací, které má závažné slabiny (Kleinknecht at al. 2001)). I při vhodné volbě ukazatelů narážíme ovšem na problémy s jejich stanovením a výpovědní hodnotou odpovídajících měření. Problematika stanovení relevantních ukazatelů efektivity a efektivnosti podpory je tak pro evaluaci podpory VaV zcela zásadní.

Přes poměrně značné množství metod a přístupů k hodnocení dopadů programů veřejné podpory, včetně podpory VaV, nelze tvrdit, že by v současné době existovala v této oblasti určitá „nejlepší praxe“ (Correa at al. 2013). Používané metody, resp. přístupy k hodnocení dopadů podpory lze dělit podle řady hledisek. Například lze rozlišit hodnocení *ex-ante*, zabývající se odhadem dopadů podpory/programu před jeho rozběhnutím (obvykle na základě strukturálních modelů) a hodnocení *ex-post*, zaměřená na analýzu dopadů po proběhnutí daného programu. Dále lze z hlediska dat rozdělit přístupy k hodnocení na kvantitativní a kvalitativní. Zatímco *kvantitativní přístupy* nabízí možnost zobecnění závěrů, kvalitativní přístupy můžou vést k lepšímu pochopení fungování (nebo nefunkčnosti) daného programu vzhledem k jeho účastníkům. Z hlediska stupně agregace dat lze v zásadě rozlišit makroekonomický a mikroekonomický přístup.

---

[1] V ČR činil v roce 2012 podíl celkových výdajů na R&D 1,88 % HDP, zároveň podíl soukromého sektoru činil 1,01 %, což znamená necelých 54 % HDP. Lze tedy říci, že ČR je v podílu soukromého financování R&D pod evropským průměrem, resp. je relativně nadprůměrná ve veřejných výdajích na R&D.

Standardními nástroji pro hodnocení efektivnosti výdajů jsou dosud obvykle relativně jednoduché indikátory založené na tzv. monitorovacích ukazatelích daného projektu resp. programu (např. počet patentů na korunu dotace, prostředky věnované na VaV ze strany firmy na dotaci apod.). Toto hodnocení ale není dostatečné, neboť monitorovací ukazatele jako takové nemusí nutně odrážet efekt podpory a mohou být silně zkreslené exogenními vlivy. V současnosti se tak dostávají postupně do popředí komplexnější nástroje zaměřené právě na řešení zmíněných exogenních vlivů. Zde nachází uplatnění zejména tzv. kontrafaktuální metody hodnocení (CIE – Counterfactual Impact Evaluation). Hodnocení dopadu intervence je zjednodušeně řečeno realizováno porovnáním skupin na programu participujících a neparticipujících subjektů. Zásadním problémem, který CIE řeší, je přitom vzájemná srovnatelnost (homogenita) podpořené a kontrolní skupiny. Výhodou kontrafaktuálního přístupu je relativně široká použitelnost a především skutečnost, že hodnotí kauzální vztahy, které mají základ v mikroekonomických datech. CIE byla v minulosti využívána především jako nástroj vědecké komunity - v odborných článcích a studiích figuruje minimálně poslední dvě dekády. Nejprve byla využívána především v oblasti medicíny, postupně však pronikla do širšího povědomí odborné veřejnosti i v dalších oborech. V současné době je využívána jako hlavní evaluační metoda řadou institucí, a to i pro hodnocení dopadů výdajů na VaV , jak lze vidět - např. ve Finsku (TEKES). O vhodnosti jejího využití a výhodách hovoří i Evropská komise (EC 2010). CIE má však i své nevýhody, mezi něž patří především její velká datová náročnost a nutnost pokročilejších znalostí kvantitativních metod. Zvláště vysoká datová náročnost nutná pro konstrukci robustních verzí metod může být někdy i překážkou jejího použití.

Přestože existuje v současné době celá řada, především zahraničních, analýz, odborných článků, studií a dalších publikací, které se přímo zabývají metodou CIE nebo ji využívají pro evaluace, je domácí literatura, především pak metodická oblast, v tomto ohledu překvapivě chudá. Dle informací, které máme v době zpracování tohoto dokumentu k dispozici, lze zřejmě za nejzdařilejší považovat metodiku MPSV (Potluka at al. 2013). Tato metodika z hlediska běžného uživatele velmi dobře popisuje jak teoretický základ CIE, tak do určité míry navrhuje řešení pro hodnocenou problematiku, kterou je Operační program zaměstnanost. Co v metodice poněkud schází, je samotná ukázka aplikace CIE, na které by bylo srozumitelně demonstrováno její využití. Co se týče využití kontrafaktuální analýzy pro hodnocení dopadů VaV, neexistuje v současné době žádná ucelená metodika využívající CIE. Dokonce je v této oblasti k dispozici jen velmi omezený počet odborných studií, resp. článků. Cílem této metodiky je potom především přiblížit tuto metodu uživateli/specialistovi tak, aby ji byl schopen účinně a správně aplikovat. Uživatel se v rámci této metodiky seznámí se standardními zavedenými postupy CIE. Metodika si tedy neklade za cíl vývoj vlastních metodických postupů, ale seznámení uživatele se standardními zavedenými postupy, a to ve dvou základních částech – teoretické a praktické. Teoretická část se stručně zabývá teoretickými základy CIE, zároveň nabízí určité zamyšlení nad kvalitou dat a cíli, ke kterým má aplikace CIE vést. Druhá část je potom praktickou ukázkou využití CIE pro hodnocení dopadů VaV na konkurenceschopnost soukromých subjektů v ČR. Vzhledem ke kvalitě a dostupnosti dat je však třeba vnímat tuto druhou část především jako demonstrativní.

2 Teoretické základy kontrafaktuální analýzy.

2.1 Podstata a podmínky kontrafaktuální analýzy

Kontrafaktuální analýza patří do rodiny kvantitativních ex *post* evaluací využívajících mikroekonomická (kvantitativní i kvalitativní) data. Hodnocení dopadu intervence je realizováno porovnáním skupin na programu participujících a neparticipujících subjektů. Časově orientované porovnání jedné skupiny subjektů před a po aplikaci programu, nazývaném někdy *reflexivní metoda*, je pro omezenou skupinu subjektů problematické z důvodu zanedbání postranních faktorů, a je tedy použitelné pouze uzavřené kompletní množiny subjektů (Ravallion 2008). Na druhou stranu porovnání participující a neparticipující (kontrolní) skupiny nese problémy separace dopadů intervence od postranních efektů. Nicméně řada metod vychází právě z tohoto schématu při vhodné modifikaci metod selekce subjektů do skupin či apriorní modifikace metod výběru participujících subjektů tak, že jednotlivé skupiny budou z hlediska programu velmi podobné.

Celkově lze říci, že výsledek subjektu závisí jak na potencionální participaci na programu, tak i na ostatních sledovaných i nesledovaných charakteristikách. Celkově lze závislost výsledku hodnocení subjektu$Y_i$rozepsat jako rovnici (Khandker at al. 2010):

$$Y_i = \alpha X_i + \beta T_i + \varepsilon_i, \tag{1}$$

kde$T_i \in \{0,1\}$ je indikátorová proměnná participace subjektu *i* na programu a X_i je množina dalších pozorovatelných proměnných majících vliv na výsledek. Nakonec $\varepsilon_i$sdružuje nepozorovatelné charakteristiky, které vykazují vliv na výsledek subjektu. Výsledkem analýz je samozřejmě efekt programu β. Jak vidíme, tak Y_i je funkcí mnoha dalších faktorů. Pokud ji pro zjednodušení zavedeme jako funkci indikátorové proměnné T_i, pak lze při daných ostatních podmínkách zavést individuální efekt intervence jako (Roy 1951; Rubin 1974):

$$\tau_i = Y_i(1) - Y_i(0).$$

Problémem samozřejmě je, že pro výpočet této funkce máme pouze jednu z hodnot, a proto se přechází k výpočtu skupinové charakteristiky *average treatment effect* (ATE):

$$\tau_{\mathrm{ATE}} = \mathrm{E}[Y_i(1) - Y_i(0)].$$

Problémem tohoto přístupu je v zahrnutí vlivu subjektů, které nebyly cílovými subjekty projektu. Proto je místo této charakteristiky počítána častěji charakteristika *average treatment effect on treated* (ATET nebo TOT) jako:

$$\tau_{\mathrm{ATET}} = \mathrm{E}[Y_i(1)|T_i = 1] - E[Y_i(0)|T_i = 1].$$

Stále ovšem zůstává problém s výrazem$E[Y_i(0)|T_i = 1]$. Ten nebývá součástí vstupních pozorování a je nutné jej nahradit. K tomuto účelu bývá využíván výraz $E[Y_i(0)|T_i = 0]$, který po přičtení k oběma stranám ve výsledku zavede odhad pro ATET jako:

τ_{ATET}=$\mathrm{E}[Y_i(1)|T_i = 1] - E[Y_i(0)|T_i = 0]$,

kde je předpokládáno, že platí vztah $E[Y_i(0)|T_i = 1] - E[Y_i(0)|T_i = 0] = 0$. Pokud tomu tak není, dostáváme systematické vychýlení tohoto odhadu v podobě výběrové chyby.

Řešením tohoto vychýlení je v ideálním případě náhodné přiřazování participace (viz dále). Ve většině případů ovšem bývá nutné klást předpoklad podmíněné nezávislosti – *conditional independence assumption* (Lechner 1999), nazývané též *unconfoundedness* (Rosenbaum a Rubin 1983). Těžištěm tohoto předpokladu je, že při dané množině sledovatelných charakteristik$X$neovlivněných potencionální participací jsou výsledky subjektů nezávislé na této participaci, neboli:

$Y(1)$,$\mathrm{Y}(0) \perp T|X$.

Je jasné, že náhodným výběrem subjektů pro participaci je možné snadno, za předpokladu dostatečně velkého statistického vzorku, dosáhnout splnění této podmínky. Nicméně přiřazování podpor v programech je často řízeno silně nenáhodným procesem, a je tedy nutné se s tímto faktem vypořádat zavedením některých metod, které budou popsány dále.

2.2 Postup CIE

Dříve, než přistoupíme k vlastnímu popisu metod CIE, měli bychom věnovat pozornost tomu, k čemu má vlastně námi provedená analýza sloužit a jak ji budeme implementovat. Zásadním krokem je korektní ex-ante definice cíle programu a výstupních (output) indikátorů (proměnných), které budou sloužit pro měření naplnění tohoto cíle. Je velmi problematické hodnotit program, jehož cílem je například „konkurenceschopnost“, pokud tato konkurenceschopnost nebyla dopředu definována a nebyly jí přiřazeny měřitelné (ať už kvantitativní nebo kvalitativní) výstupní indikátory. Definování výstupních indikátorů by mělo probíhat v rámci širší diskuze mezi zadavatelem, příjemci podpory a odbornou veřejností. Výstupní indikátory **musí být relevantní a v souladu s vytyčeným cílem, vhodně měřitelné a samozřejmě datově dostupné v požadované kvalitě**. Otázkou je také správné definování časového rámce analýzy. V zásadě jsou klíčová tři období, a to období před podporou, období podpory (to obvykle jednoznačně dáno) a období po podpoře. Je otázkou, jak dlouhá by měla být sledovaná období před a zejména pak po podpoře – ani zde dosud neexistuje obecně platný konsensus (např. agentura TEKES pracuje s maximálním horizontem 5 let). Prodlužování této délky je obecně hodnoceno kladně. Nutno však podotknout, že s růstem délky období roste i pravděpodobnost zahrnutí dalších vlivů, které by neměly do analýzy vstupovat. Kromě výstupních proměnných je třeba najít shodu a definovat další proměnné, které budou do evaluace vstupovat (tzv. *covariates*). Dopředu tedy musí být známa struktura kontrafaktuálního modelu tak, aby zadavatel mohl ve spolupráci s příjemci podpory a dalšími subjekty (zejména budoucími neúspěšnými žadateli) vytvářet kvalitní datový podklad pro aplikaci CIE – a to jak v období před podporou, tak po ní. Jak bylo uvedeno výše, kontrafaktuální analýza je extrémně náročná na data, a to nejen na jejich množství ale především na kvalitu. Pokud nejsou použita relevantní data, potom byť metodicky

správně provedená analýza, bude podávat zkreslené nebo zcela nerealistické[2] výsledky. V případě hodnocení efektivity veřejných výdajů je přitom spolehlivost evaluací zcela klíčová – nesprávně provedená evaluace s sebou může nést další společenské náklady (např. některý druh podpory ve světle evaluace zanikne nebo naopak bude podpora nesprávně rozšířena). Velmi důležitou součástí tvorby datového zdroje je tak způsob získávání dat a jejich dostupnost. Postup při přípravě programu, který má být hodnocen pomocí ex-post kontrafaktuální analýzy lze znázornit a popsat takto:

Obrázek 1: Schéma implementace hodnocení programu pomocí CIE

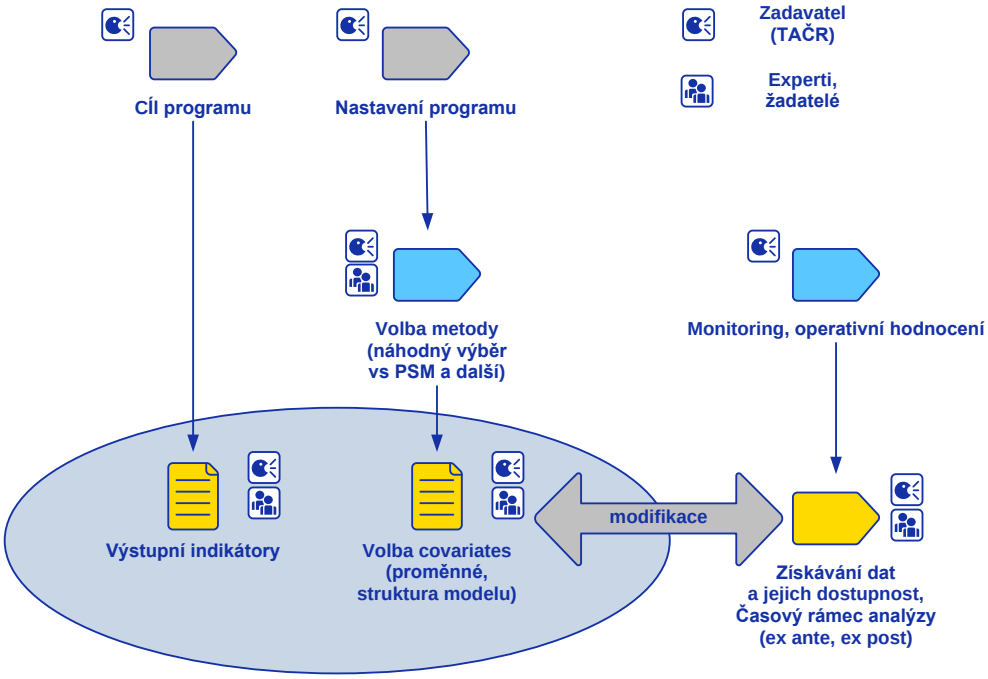

1. Definování cíle programu (např. zvýšení konkurenceschopnosti) a časového rámce analýz (období před podporou, období podpory a období po podpoře).

2. Definování výstupních indikátorů - proměnných (přidaná hodnota, počet zaměstnaných, patenty, certifikované metodiky, soukromé výdaje na VaV…).

3. Volba vhodné metody, volba covariates a struktury modelu.

4. Definování a volba metodiky získávání dat, analýzy dostupnosti dat (před, v průběhu a po skončení programu).

5. Monitoring a operativní hodnocení, získávání dat v běhu programu, úpravy metod získávání dat a případně úpravy (drobné) modelu v závislosti na tom, s jakou úspěšností jsou data získávána.

---

[2] v zahraniční literatuře najdeme často pro tuto situaci poměrně přiléhající výraz „garbage in, garbage out“

Participující skupiny: žadatelé o podporu, zadavatel (hodnotitel), expertní skupina (odborná veřejnost)

V rámci kapitoly 3.1 jsme se zabývali problematikou použití kontrafaktuální analýzy. V další kapitole se budeme věnovat metodám reprezentujícím nejčastější modifikace základního přístupu k získání robustnějších výsledků. V následující sekci budeme stručně diskutovat jednotlivé přístupy k hodnocení dopadu intervence:

- metodu náhodného výběru (random selection),
- propensity score matching (PSM),
- metodu double difference, resp. difference in difference (DD),
- metodu využívací instrumentálních proměnných a
- diskontinuitní regresi (RDD).

Jde o standardní přístupy k dopadovým evaluacím, které lze nalézt v prakticky jakékoli relevantní literatuře (např. Shahidur 2010).

3 Metody CIE

3.1 Náhodný výběr (randomizace)

Náhodný výběr je relativně nenáročnou metodou CIE založenou na náhodné selekci subjektů do programu, což vede k naplnění popsaného předpokladu unconfoundness. Jeho nevýhodou je ovšem omezená využitelnost, neboť většina programů podpory, včetně podpory R&D, nemá z pochopitelných důvodů selekci založenou na náhodném výběru. S metodou náhodného výběru se můžeme setkat typicky v medicíně. Typicky je používán dvoufázový náhodný výběr, kde v první fázi hodnotitel náhodně vybere z relevantní populace subjektů reprezentativní vzorek. Tento vzorek musí být robustní a dostatečně velký, čímž je zajištěna externí validita odhadu. V druhé fázi je potom subjektům z tohoto vzorku náhodně přiřazena intervence (podpora), zároveň jsou z této skupiny náhodně vybrány subjekty do kontrolní skupiny. Tím je zajištěna interní validita odhadu – odpadá problém se vznikem výběrové chyby adresovaný výše.

Randomizace může proběhnout v čisté formě (*pure randomization*) nebo tzv. částečnou randomizací (*partial randomization*). Čistá forma je používána poměrně zřídka. Částečná randomizace provádí náhodný výběr za určité podmínky. Například vybíráme náhodně z populace jednotlivců se stejnou úrovní příjmů[3]. Tato podmíněná proměnná nicméně nesmí žádným způsobem ovlivňovat to, zda bude subjekt přiřazen do podpořené skupiny či nikoli (*conditional exogeneity of program placement*). Vzhledem k tomu, že každý subjekt, který v CIE odhadu bude figurovat, se nachází buď v podpořené, nebo nepodpořené skupině (nikdy v obou), bude pro efekt podpory Y_i zároveň platit $Y_i = [Y_i(1)T_i] + [Y_i(0)(1 - T_i)]$. Označme pro další použití výstupní proměnnou s absencí podpory, tj. výstupní proměnnou u nepodpořené skupiny $Y_i(0) = Y_{i(C)}$a $Y_i(1) = Y_{i(T)}$pro proměnnou s podporou tj. z podpořené skupiny. Rovnice (1) potom může být pro obě skupiny, kde *T* je podpořená a *C* kontrolní skupina, a při zahrnutí konstanty b_0 zapsána jako (Ravallion 2008)

$Y_{i(T)} = b_{0(T)} + \alpha X_{i(T)} + \varepsilon_{i(T)}$ pro *T* = 1 a

$Y_{i(C)} = b_{0(C)} + \alpha X_{i(C)} + \varepsilon_{i(C)}$ pro T = 0.

Rovnice lze přetransformovat[4] do podoby

$$Y_i = b_{0(C)} + (b_{0(T)} - b_{0(C)})T_i + \alpha_C X_i + X_i(\alpha_{(T)} - \alpha_{(C)})T_i + \varepsilon_i, \quad (2)$$

kde $\varepsilon_i = T_i(\varepsilon_{i(T)} - \varepsilon_{i(C)}) + \varepsilon_{i(C)}$. Efekt podpory v rovnici (2) potom může být vyjádřen jako

$$\mathrm{ATET} = b_{0(T)} - b_{0(C)} + X_i(\alpha_{(T)} - \alpha_{(C)}).$$

---

[3] obecně jde o parametry v rovnici (1)

[4] první rovnici vynásobíme T a druhou (1-*T*) a použijeme vztah pro disjunktní efekt podpory uvedený v textu.

Rovnice (2) je v aplikacích standardně odhadována jako regresní rovnice metodou nejmenších čtverců (OLS) s tím, že je třeba dodržet všechny statistické náležitosti spojené s touto metodou odhadu (homoskedasticita, normalita atd.). Obvykle se také v praxi předpokládá rovnost $\alpha_{(T)}$= $\alpha_{(C)}$ a efekt podpory je potom definován jako $\mathrm{ATET} = b_{0(T)} - b_{0(C)}$.

Existuje několik přístupů k praktické implementaci randomizace (viz Khandker 2010), z nichž zajímavým přístupem především z hlediska ex-ante evaluací je tzv. náhodné fázování (*randomized phase-in*). V podstatě jde o to rozfázovat implementaci programu tak, že nejprve je podpora přidělena náhodně pouze části subjektů a zbytek skupiny funguje jako skupina kontrolní. Lze si představit aplikaci této metody např. u pilotních projektů – z přihlášených (a vyhovujících) subjektů se náhodně vybere skupina, která bude podpořena a bude porovnávána s pseudo-podpořenou, resp. kontrolní skupinou, tedy zbytkem. Výhodou je pravděpodobně vyšší homogenita obou celků. Kromě náhodného fázování stojí za pozornost také náhodné oslovení potenciálních participujících (*random encouragement*). Zde nejde o náhodné přidělování podpory, ale o náhodné informování, resp. nabídku podpory subjektům a náhodné informování veřejnosti. Výhodou je teoreticky lepší možnost postižení tzv. spillover efektů (viz dále), zejména pokud jsou data sbírána pomocí sociálních sítí, nicméně náročnost kladená na sběr dat bude pravděpodobně extrémní.

Problémy randomizace

Přístup k evaluacím pomocí náhodného výběru bývá poměrně často označován jako „nejčistší“, nicméně také se potýká s řadou problémů. Kromě toho, že v praxi řada programů není implementována pomocí náhodného přidělování podpory, což využitelnost tohoto přístupu značně limituje, jde především o otázky externí validity a tzv. spillover efekty. U externí validity jde především o problém zobecnění daného hodnocení efektů. Náhodný vzorek musí být dostatečně velký, abychom se přiblížili k teoretickým hodnotám a musí být vybrán z jasně definované populace. Zmiňovaná externí validita je dobře vidět u probíraných pilotních projektů, kde hodnocení na relativně malé skupině pozorování nemusí dobře odrážet skutečný konečný dopad daného programu. U spillover efektů může docházet k tomu, že díky provázanosti podpořených subjektů a subjektů v kontrolní skupině (např. na bázi odběratelsko-dodavatelských vztahů) je hodnocení efektu podpory zamlženo tím, že podpora se implicitně projeví i u subjektů v kontrolní skupině. Částečně lze tento problém řešit prostorovou separací kontrolní a podpořené skupiny, nicméně obecně je tento problém obtížně řešitelný, zvláště pokud se spillover efekty vyskytují na agregátní nebo globální úrovni. Pokud jde o efekty lokální, lze je do určité míry řešit (Miguel, Kremer 2004).

Kromě těchto dvou zásadních problémů, se kterými se náhodný výběr může potýkat, je třeba zmínit i relativně obtížně politicky obhajitelnou náhodnost zařazení do programu/přidělení podpory. Je třeba si uvědomit, že nepodpořené subjekty z populace se mohou cítit nespravedlivě vyloučeny.

Využitelnost náhodného výběru pro hodnocení podpory soukromých subjektů v oblasti VaV.

Vzhledem k výše uvedenému je **nepravděpodobné, že by tento přístup mohl být využit**, a to zejména z toho důvodu, že současné nastavení podpory není náhodné, ale podpora je přidělována na základě žádosti a vyhodnocení projektu. Lze nicméně uvažovat do budoucna o oblastech, kde by tento přístup byl využitelný (např. piloty pro testování efektivnosti zvažovaného programu).

3.2 Propensity score matching (PSM)

Zatímco předchozí metoda náhodného výběru byla schopna do značné míry potlačit výběrovou chybu díky samotné povaze výběru skupin, následující metody již musí s tímto problémem pracovat a randomizaci de facto simulovat. Běžný je již výše zmiňovaný předpoklad podmíněné nezávislosti, resp. *uncounfoudness*. Na tomto základě jsou postaveny další dvě metody – metoda propensity score matching (PSM) a metoda double difference (DD). Metoda instrumentálních proměnných řeší problém jinak – pomocí instrumentů, které korelují s rozhodováním o participaci subjektu v programu ale nikoli výstupní proměnnou.

Základní myšlenkou *Propensity score matching* (PSM), je to, že se snaží vytvořit kontrolní (kontrafaktuální) skupinu takovou, která je co nejvíce podobná skupině podpořené. Podobnost je přitom určena na základě pozorovaných proměnných (*covariates* - X_i). Tyto charakteristiky jsou sledovány typicky v období před podporou a neměly by tak být participací v programu ovlivněny. Modelem podobnosti je pravděpodobnostní model participace v programu reprezentovaný charakteristikou nazývanou propensity score, která na základě pozorovaných proměnných určuje pravděpodobnost participace subjektu v programu (logistická regrese nebo probit) počítané z pozorovaných charakteristik $P(X)$ nazývané *propensity score* (Rosenbaum a Rubin 1983). Participující subjekty jsou dále přiřazeni odpovídajícím neparticipujícím subjektům dle shody tohoto propensity score párovacími algoritmy[5]. Použitý párovací algoritmus typicky závisí na charakteru dat. Ze známých metod lze jmenovat například Nearest-neighbor či Kernel matching. Výsledné porovnání lze spočítat jako ATET mezi výše zmíněnými skupinami. I zde platí předpoklad podmíněné nezávislosti, který je navíc rozšířen o podmínění na propensity score (Rosenbaum a Rubin, 1983):

$$Y(1),\mathrm{Y}(0) \perp T|P(X).$$

Druhou důležitou podmínkou pro implementaci PSM je podmínka *common support*. Ta říká, že participující subjekty mají své kontrolní subjekty blízko položené v míře propensity score. Jinými slovy subjekty se stejným X mají kladnou pravděpodobnost participace a stejně tak i kladnou hodnotu opačné pravděpodobnosti, tj.

$$0<\mathrm{P}(\mathrm{T}=1|X) < 1.$$

[5] Převedení řady proměnných do jednoho skóre redukuje problém, resp. tzv. „prokletí dimenzionality“, které nastává v případě, že se snažíme napárovat subjekty podle několika proměnných najednou.

Podmínka vlastně říká, že existuje dostatečně veliká množina participantů a jí odpovídající podobně velká množina neparticipujících subjektů. Tyto množiny se posléze mohou stát těmi, které bude metoda porovnávat. Ačkoliv se vyskytují některé metody na odhadnutí common support, nejčastější metodou je vizuální inspekce rozdělení hustoty propensity score u porovnávaných skupin (Lechner, 2001).

Pro stanovení propensity score se vybírá vhodný model. Při binární indikátorové funkci je častou volbou logistická nebo probabilistická regrese (logit, probit). Existují i možnosti rozšíření modelu zahrnující škálování charakteru participace použitím multinomiálního probitu (Caliendo a Kepeinig, 2008). Jelikož má tento přístup i mnohé nevýhody a omezení, je rozumné při různé výši podpory začít s binárním přístupem spojeným s vhodnou interpretací výsledků a dle charakteru závěru z tohoto hodnocení posléze potencionálně přistoupit k možné implementaci rozšíření (to nicméně není součástí předkládané metodiky). Důležitý je také výběr proměnných do modelu, který musí brát v úvahu všechny možné aspekty, jelikož vynecháním důležitých proměnných můžeme způsobit velké zkreslení (Heckman at al. 1997). Stejně tak ovšem existuje i problém s „přeparametrizováním“ modelu zahrnutím velkého množství proměnných (Bryson at al. 2002). K celkovému výběru vhodných indikátorů je třeba citlivé analýzy s možným zahrnutím statistických testů signifikance uvažovaných proměnných. Pozorované proměnné X_i by měly být teoreticky voleny tak, aby mohly ovlivňovat rozhodnutí subjektu o participaci, ale neovlivňovaly výstupní proměnnou.

Jelikož je pro fungování PSM důležité vybrat vhodný algoritmus pro párování participantů a neparticipujících subjektů, existuje velké množství variant algoritmů, ze kterých vybrat pro implementaci daného kroku. Z používaných metod lze vybrat mezi: párováním s nebližším sousedem (*nearest neighbour matching - NNM)*, párování na základě nejbližšího regionu (*caliper* nebo *radius matching)*, stratifikaci a intervalové párování, kernelovo a lokální párování. Výběr vhodného algoritmu závisí na charakteru analyzovaných dat a je tedy spíše otázkou v určitém kroku celkového projektu. Přestože je v současnosti hojně využíván zejména *NNM* (zejména v praktických aplikacích) a Kernel *matching* (zejména v odborných článcích), obecně lze doporučit aplikaci více metod zároveň a z jejich výsledků usuzovat na pravděpodobný výsledek (viz Shahidur 2010). Pro zevrubný popis jednotlivých algoritmů není dostatek místa, a proto odkazujeme například na publikaci (Caliendo a Kepeinig 2008).

Konečným krokem je statistické testování výsledků. Obecně vhodnou publikací pro přehled jednotlivých metod je zmiňovaná publikace (Caliendo a Kopeinig 2008). Kromě možného testování kvality párování, je hlavním bodem odhad variance ATE(T). Jednou z možností je *bootstrapping*, který opakuje proces pro několik vzorků dat a umožňuje tak získat odhad variance. Existují také kritiky této metody v určitých podmínkách, nicméně za tímto účelem je stále tato klasická metoda vhodná (Imbens 2004).

Efekt podpory lze po aplikaci PSM vyjádřit obecně jako (Heckman, Ichimura, a Todd, 1997; Smith a Todd, 2005)

$$\text{ATET} = \frac{1}{N_{(T)}} \sum_{i \in T} [Y_{i(T)} - \sum_{j \in C} \omega(i,j) Y_{j(C)}], \quad (3)$$

kde *N* je počet podpořených subjektů a ω je váha použitá pro agregaci výstupů subjektů v kontrolní skupině. Tato váha závisí na metodě, která je použita pro párování.

Postup aplikace PSM

Primárním cílem PSM je nalézt kontrolní skupinu takovou, která bude co možná nejblíže skupině podpořené v tzv. pozorovaných charakteristikách (covariates – *X*). Pochopitelně je třeba vybrat vhodné covariates – tedy ty, které

a) nejsou ovlivněny programem a

b) mohou ovlivnit rozhodování o vstupu do programu a zároveň výstupní proměnnou.

Postup při aplikaci PSM lze shrnout do následujících bodů:

1. Definovat strukturu modelu – výstupní proměnné a pozorované proměnné (*covariates*). Tento první bod platí prakticky pro všechny přístupy kontrafaktuální analýzy popsané v této metodice. Je třeba jasně definovat výstupní proměnnou (proměnné) v souladu s cílem programu. Např. pro konkurenceschopnost si lze představit proměnnou přidaná hodnota (buď absolutně nebo intenzifikovaně - na odpracovanou hodinu či na přepočteného zaměstnance). Dále je nutné definovat *covariates*. V tomto případě například velikost firmy, NACE, NUTS, výše aktiv v období před podporou apod. Relevance covariates je zcela klíčová.

2. Aplikovat regresní analýzu (probit nebo logit), kde závislou proměnnou je participace na projektu. Tedy pro podpořenou skupinu T = 1, pro nepodpořené subjekty (ideálně neúspěšné žadatele) T = 0. Tento krok ukáže, jaké covariates měly vliv na participaci v projektu. Pokud je podpora nebinární, je doporučeno využít multinominální probit nebo řadu binominálních modelů (Caliendo a Kopening 2008).

3. Výpočet předpovídaných hodnot (*predicted value*) parametru *T* na základě odhadnutého logistického nebo probabilistického modelu pro obě skupiny. Předpokládaná hodnota *T* ukazuje na pravděpodobnost, s jakou daný subjekt (ať už ve skutečnosti podpořený či nepodpořený) dosáhne na podporu. Tato hodnota je dále označena jako *propensity score*. Přestože výsledky modelu nemusí být v této fázi statisticky významné (t-statistiky, nízké R^2), neznamená to, že je model nefunkční. Jak bylo uvedeno výše, pro správně odhadnuté *propensity score* je zásadní relevance *covariates*, resp. klíčové je získat správné rozdělení pravděpodobností podpory. Nezahrnutí klíčových *covariates* nebo špatná kvalita zahrnutých dat může odhad propensity score výrazně poškodit. Je přitom poměrně nesnadné tento problém řešit na základě statistických testů – v podstatě nejsou. Heckman, Ichimura, Todd (1997, 1998) navrhují problém ne-relevance covariates minimalizovat tak, že:

    a. Pro participující i neparticipující (kontrolní) subjekty je zvolen stejný datový zdroj.

b. Oba vzorky by měly být reprezentativní, tedy dostatečně velké, resp. robustní. Navíc čím větší bude vzorek dat u kontrolní skupiny, tím přesnější a snazší bude napárování (*common support* bude vydatnější).

c. Obě skupiny by měly být vystaveny podobným vnějším vlivům, zejména by měly mít podobný zájem o participaci na podpoře. Je proto vhodné do kontrolní skupiny zahrnout především neúspěšné žadatele o podporu z podobné geografické oblasti, odvětví apod.

d. Není dobré zahrnovat příliš velký počet *covariates*. Hrozí „přeučení“ modelu.

4. Definice *common support* a testy rovnováhy (*balancing tests*).

Jak bylo zmíněno výše, je třeba nalézt překryv mezi propensity scores obou skupin. Řada pozorování z obou skupin může vypadnout. Pro dodržení shody mezi oběma skupinami je v rámci intervalů (kvantilů) prováděn test rovnováhy – jde v zásadě o test **shody středních hodnot** a **shody rozdělení** *propensity score* v jednotlivých blocích. Pokud tento test neprojde, je třeba obvykle upravit covariates (například některý z modelu vypustit). Lze provést i doplňkové testy jako je např. Koglomorov-Smirnovův test.

5. Párování

Jak bylo uvedeno výše, existuje řada metod párování na základě propensity score. V tomto bodě se omezíme pouze na jejich stručnou charakteristiku. Pro další informace lze doporučit např. Caliendo a Kepeinig (2008) nebo Khandker (2010). Výběr techniky/metody párování s sebou zároveň nese určení vah. Váhy se obecně vztahují k subjektům, které jsou napárovány z kontrolní skupiny, kdy jde o převážení výsledku na základě rozdělení skóre v podpořené skupině (zjednodušeně řečeno jde o vážený průměrný efekt, kdy váhami je relativní četnost jednotlivých skóre v podpořené skupině). Zvolením dané metody párování tedy lze ovlivnit váhy a konečný výsledek efektu dopadu.

a. Metoda nejbližšího souseda (*nearest neighbour* – NN). Jde o v praxi pravděpodobně nejrozšířenější metodu, kdy daný podpořený subjekt je napárován subjektem z kontrolní skupiny, který má nejbližší skóre. Těchto nejbližších sousedů může být i více (obvykle se doporučuje 5). Párování může probíhat s vracením nebo bez vracení – daný nepodpořený subjekt se může v případě vracení vyskytnout několikrát.

b. *Caliper* a *radius matching.* Běžný problémem při aplikaci NN je to, že nejbližší soused může být ve skutečnosti relativně daleko. Tento problém lze vyřešit nastavením určité hladiny tolerance, tedy maximální hodnoty, o kterou se skóre párovaného subjektu může odchýlit od skóre podpořeného subjektu – spárované subjekty jsou tedy z určité definované oblasti. Nebezpečím je ovšem možnost výrazné redukce vzorku a s tím rostoucí riziko *sample bias*.

c. Stratifikace a intervalové párování (*interval matching*). Tato metoda rozdělí množinu *common support* na několik intervalů, přičemž provádí hodnocení dopadu programu na každém z těchto intervalů. Výsledný efekt je potom váženým průměrem, kdy

vahami je velikost jednotlivých intervalů (měřeno počtem, resp. podílem subjektů v intervalu k celku).

d. *Kernel matching* a *local linear matching* (*LLM*). Předchozí metody mají jednu společnou nevýhodu, a sice že nakonec může zbýt poměrně malá skupina v *common support*, která bude vyhovovat párovacím podmínkám. *Kernel matching* a *LLM* jsou neparametrické metody využívající vážený průměr subjektů z kontrolní skupiny. Pro váhy ω_{ij} v tomto případě platí

$$\omega(i,j) = \frac{K\left(\frac{P_j - P_i}{a_n}\right)}{\sum_{k \in C} K\left(\frac{P_k - P_i}{a_n}\right)},$$

kde *K* je Kernelova funkce (non-negativní funkce s průměrem 0 a součtem 1) a a_n je vyhlazovací parametr. *LLM* je založeno na podobném základě s tím rozdílem, že neodhaduje váhu jako konstantu ale odhaduje ji jako lineární funkci.

6. Odhad dopadů intervence (podpory)

Jak již bylo naznačeno výše, pokud jsme provedli párování (určitou metodou) a máme *common support*, je relativně snadné určit průměrný efekt podpory ATE jako rozdíl v průměrné hodnotě dané výstupní proměnné mezi oběma celky, přičemž jsou aplikovány váhy podle distribuce skóre v podpořené skupině.

Vzhledem k tomu, že je často vhodné redukovat výběrovou chybu, způsobenou nepozorovanými (nicméně v čase invariantními) proměnnými, bývá často pro odhad efektů využito změn ve výstupních proměnných. Jde tedy o kombinaci metody difference in difference (DD) a PSM. Samostatný přístup k hodnocení dopadů metodou difference in difference (nebo také double difference) bude podrobněji diskutován v následující podkapitole. Jak již bylo zmíněno výše, hlavní předností tohoto přístupu je schopnost do určité míry potlačit vliv nepozorovaných vlivů, resp. snížit možnou výběrovou chybu. Jde o to, že tato metoda sice připouští určitou heterogenitu mezi skupinami, nicméně předpokládá, že tato heterogenita se v čase nemění – lze ji tedy pomocí diferencí (v čase) odstranit. DD využívá standardně dva časové úseky – před podporou (t0) a po podpoře (t1). Průměrný efekt podpory na common support je potom v případě panelových dat obecně dán takto

$$\mathrm{ATET} = \frac{1}{N_{(T)}} \sum_{i \in T} [(Y_{i1(T)} - Y_{i0(T)}) - \sum_{j \in C} \omega(i,j)(Y_{j1(C)} - Y_{j0(C)})] \tag{4}$$

v případě průřezových dat potom

$$\mathrm{ATET} = \frac{1}{N_{(T2)}} \sum_{i \in T2} [Y_{i1(T)} - \sum_{j \in C2} \omega(i,j) Y_{j1(C)}] - \frac{1}{N_{T1}} \sum_{i \in T1} [Y_{i0(T)} - \sum_{j \in C1} \omega(i,j) Y_{j0(C)}] \tag{5}$$

Kromě toho lze například aplikovat regresní analýzu na *common support* nebo zvlášť na obě skupiny (tzv. diskontinuitní regrese - RDD). Jde v podstatě o odhad lineární regresní rovnice (podobně jako u

randomizace) ve tvaru $Y_i = b_0 + \alpha T_i + \beta(X_i) + \varepsilon_i$. Tento přístup opět podobně jako DD umožňuje minimalizovat vliv nepozorovaných faktorů, které jsou invariantní v čase.

Problémy a kritika PSM

Základní problémem PSM je zřejmě existence nepozorovaných proměnných, které mohou ovlivnit participaci v programu a výstupní proměnnou. Pokud se lze domnívat, že takovýchto faktorů je vzhledem k povaze programu zanedbatelné množství, resp. jejich síla je malá, potom PSM poskytuje velmi solidní odhady, srovnatelné s náhodným výběrem. Problémem je, že tento předpoklad je prakticky statisticky neověřitelný. Je nicméně možné alespoň částečně pokrýt tento problém získáváním zejména kvalitativních dat od subjektů (podpořených i nepodpořených) pomocí dotazníků apod. Zároveň je třeba danému programu dobře rozumět, aby byla definice *covariates* co nejkvalitnější.

Dalším problémem, se kterým se PSM potýká, je nedostatek dat, resp. problém interní versus externí validity. PSM slouží především k zajištění interní validity, tedy redukci výběrové chyby. Při malém počtu dat z kontrolní skupiny ale může k výběrové chybě přesto dojít. Navíc PSM téměř vždy poměrně výrazně redukuje kontrolní skupinu. Může se stát, že množina *common support* bude relativně malá, což může v důsledku znamenat výrazné snížení externí validity modelu tj. robustnosti a schopnosti generalizace. Celkově lze doporučit aplikaci PSM pouze v případě, že existuje dostatečně velká podpořená a zejména nepodpořená (kontrolní) skupina subjektů (viz Mirošník et al 2014).

Využití PSM pro TAČR

Pro účely hodnocení podpory soukromých subjektů v oblasti VaV je metoda PSM vhodná. Je nicméně třeba zajistit dostatečnou datovou vydatnost a správně zvolit *covariates*. Volba covariates, stejně jako volba výstupních proměnných, by měla být otázkou diskuze a širšího konsensu. Lze také uvažovat o dotazníkových šetřeních, popřípadě dalších metodách, které pomohou identifikovat možné nepozorované proměnné, zkvalitnit výběr covariates a v důsledku snížit výběrovou chybu. V rámci PSM se potom jako nejvhodnější jeví kombinace s DD, která umožňuje snížení, resp. odstranění heterogenity mezi skupinami v případě, že je tato heterogenita časově invariantní.

3.3 Double difference

Double difference (DD), někdy také označována jako *difference in difference*, byla částečně diskutována výše jako možná součást PSM. Její výhodou je předpoklad možné heterogenity v datech, přičemž tato heterogenita je v čase neměnná (invariantní). DD obvykle využívá panelová data, narozdíl od PSM a náhodného výběru, kde jde o obvykle o data průřezová[6]. DD využívající panelová data v zásadě porovnává změny ve výstupních proměnných a covariates ve dvou periodách – před (t0) a po (t1) intervenci. Obecně tedy odhadujeme efekt podpory takto

[6] Jak jsme ale ukázali u PSM double difference může být využito i v případě průřezových dat.

$$\mathrm{DD} = E(Y_{1T} - Y_{0T}|T_1 = 1) - E(Y_{1C} - Y_{0C}|T_1 = 0). \tag{6}$$

Jak již bylo zmíněno, DD umožňuje nepozorovanou heterogenitu v datech, tedy situaci, která při normální aplikaci PSM může vést k výběrové chybě. Například se může jednat o náboženské vyznání subjektů v kontrolní a podpořené skupině. Přestože tato charakteristika může ovlivnit výstupní proměnnou, ovlivňuje ji v čase stále stejně, tedy neovlivní její změnu. Kalkulace se změnou tak efektivně vliv této nepozorované charakteristiky vyloučí.

Obrázek 2: Příklad DD

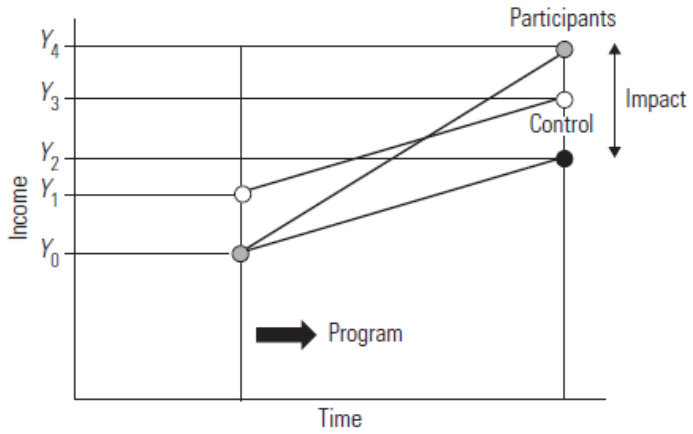

Zdroj: Shahidur 2010

DD a regrese, fixní efekty

DD je často, kromě využití spolu s PSM, využívána v kombinaci s regresí. Odhadovaná regresní rovnice má podobu

$$Y_{\mathrm{it}} = b_0 + \alpha(T_{i1})t + \beta(T_{i1}) + \gamma(t) + \varepsilon_{\mathrm{it}} \tag{7}$$

Klíčový je přitom odhad parametru α, který ukazuje na efekt daného programu podpory. Proměnné *T* a *t* zároveň vystupují v rovnici samostatně z důvodu zachycení ostatních efektů souvisejících s časem nebo zařazením do programu. Aby byl DD odhad správný, je třeba dodržet podmínku nezkorelovanosti reziduí s proměnnými v regresním modelu tj. s proměnnou (T_{i1}), (t)a $(T_{i1})t$. Poslední podmínka ukazuje právě na předpoklad časové invariance nepozorovaných proměnných.

Regresní DD model může být rozšířen o fixní efekty. Toto rozšíření je užitečné v případě, kdy kromě nepozorovaných, časově neměnných, proměnných vstupují do modelu covariates, které se v čase mění (rovnice 7 tuto změnu apriori nepředpokládá, resp. nezahrnuje covariates). Rovnice (7) tak může být modifikována takto

$$Y_{\mathrm{it}} = \alpha(T_{\mathrm{it}}) + \beta(X_{\mathrm{it}}) + \gamma_i + \varepsilon_{\mathrm{it}}, \tag{8}$$

kde γ_i zahrnuje časově invariantní nepozorované heterogenní efekty a zahrnuje časově variabilní covariates (pozorované). Diferenciací (8) podle času získáme

$$\Delta Y_{it} = \alpha\Delta(T_{it}) + \beta\Delta(X_{it}) + \Delta\varepsilon_{it}, \quad (9)$$

změna proměnné je dle předpokladů v čase nulová. Efekt programu je potom vyjádřen odhadnutým parametrem, přičemž slouží jako kontrolní proměnné.

Výhody a nevýhody DD, kombinace PSM a DD

Nespornou výhodou DD je relativně jednoduchá aplikace, ve srovnání s PSM také nižší datová náročnost a schopnost odhadovat dopady i za předpokladu heterogenních nepozorovaných faktorů. Zde je ovšem také kámen úrazu DD. Základním předpokladem totiž je, že se tyto nepozorované proměnné v čase nemění, což ale v praxi často není pravda. DD potom může produkovat vychýlené a nesprávné výsledky. Jako optimální (přestože ne zcela perfektní) se jeví kombinace PSM a DD zmiňovaná dříve. PSM by mělo zajistit srovnatelnost obou skupin ve sledovaných charakteristikách, lze tedy předpokládat, že i případný vývoj nepozorovaných charakteristik by mohl být podobný. Úspěch tohoto přístupu nicméně závisí především na kvalitě dat v období před participací v programu.

Využitelnost pro TAČR

DD lze využít samostatně nebo v kombinaci s PSM. Vzhledem k výše uvedenému se kombinace s PSM jeví jako optimální.

3.4 Instrumentální proměnné

Metoda instrumentálních proměnných dovoluje zohlednit endogenitu sledované proměnné participace. Podobně jako v případě metody double difference (DD) jsou i zde využívána panelová data, kde můžeme předpokládat i časově proměnnou výběrovou chybu. V případě metody DD ovšem nelze kontrolovat výběrovou chybu měnící se v průběhu času. Uvolněním předpokladu exogenity se odlišuje metoda odhadu instrumentálních proměnných od předchozích metod.

Základem této metody je nalezení proměnných (též označované jako *instrumentální proměnné*), které korelují s rozhodováním o participaci subjektu v programu, ale nikoli s nepozorovanými proměnnými ovlivňující výstupní proměnnou. Jinak řečeno jedná se zjednodušeně o proměnné, které poskytnou dostatečnou variabilitu a jsou tedy dobrým prediktorem získání podpory, ale zároveň neovlivňují výsledek podpory.

Výběr instrumentů je ovšem velmi citlivá operace, která může v pozitivním případě pomoci, nicméně může také původní systematické vychýlení zvětšit. Toto riziko lze částečně zmírnit testováním vybraných instrumentů, o kterém se zmíníme později.

Mezi používané instrumentální proměnné patří například osoba evaluátora, který na jednu stranu ovlivňuje přijetí projektu, ale zároveň na něm není závislý výsledek podpory. Osobu hodnotitele však

lze využít jen v případě, kdy se hodnocení evaluátorů od sebe významně liší, což nebývá cílem instituce poskytující podporu.

Časovou proměnlivost heterogenity nepozorovaný proměnných řeší metoda instrumentálních proměnných za pomoci panelových dat. Problémem dat bývá korelace mezi participačním indikátorem T_i a nepozorovanými charakteristikami v chybovém vektoru ε_i. Jelikož nelze předpokládat jako u metody double difference (DD) časovou nezávislost u těchto nepozorovaných proměnných, využívá metoda instrumentálních proměnných nalezení nové proměnné Z_i, která bude nekorelovaná s participační proměnnou a korelovaná s chybovým vektorem:

$$\begin{aligned} cov(Z_i, T_i) &\neq 0 \\ cov(Z_i, \varepsilon_i) &= 0 \end{aligned} \tag{10}$$

Pro použití instrumentální proměnné pro odhad dopadu intervence existují dva základní přístupy. Jedná se o metodu Waldova estimátoru a o dvoustupňovou metodu nejmenších čtverců (dvoustupňovou regresi).

Waldův estimátor se používá pro ty nejjednodušší situace, kdy je uvažován pouze jeden instrument. Waldův estimátor lze uplatnit pouze na binární instrumenty a neumožňuje využití kontrolních proměnných. Pro překonání těchto omezení, bývá v praxi často používán složitější postup založený na základě dvoufázové regrese.

Vrátíme-li se ke vztahu (1)

$$Y_i = \alpha X_i + \beta T_i + \varepsilon_i$$

není výběrová chyba problém, pokud je přidělení podpory *T* náhodné. Tento případ však nemůže nastat, neboť s výstupem *Y* jsou korelované pozorované či spíše i nepozorované specifičnosti podporované oblasti. Důvodem je mnoho socioekonomických vlivů daných cíli a oblastmi programu a přítomnost self-selekce.

K izolaci části indikátorové proměnné participace T_i, která je nezávislá na dalších nepozorovaných charakteristikách ovlivňujících výsledek můžeme modelovat závislost *T* na instrumentech *Z* a ostatních proměnných v rovnici (1) pomocí jednostupňové regrese:

$$T_i = \gamma Z_i + \phi X_i + u_i \ . \tag{11}$$

Predikovaná proměnná reflektuje pouze část podpory danou *Z*, tedy jen exogenní variabilitu podpory. Po dosazení odhadu proměnné participace do rovnice (1) dostáváme

$$Y_i = \alpha X_i + \beta(\gamma Z_i + \phi X_i + u_i) + \varepsilon_i \ , \tag{12}$$

$\hat{\beta}$ je pak odhad dopadu podpory (2SLS). Při splnění předpokladů uvedných ve vztahu (10) model identifikuje střední dopad programu připadající na instrument.

Nevýhoda metody spočívá především ve velké datové náročnosti, neboť je nutné získat data i pro instrumentální proměnné, a problematickém nalezení vhodných relevantních a zároveň exogenních instrumentů. Je-li instrument Z_i korelovaný s nepozorovanými charakteristikami ovlivňujícími výsledek, a tedy

$$cov(Z_i, \varepsilon_i) \neq 0 \ , \tag{13}$$

bude odhad efektu programu zkreslený. V případě pouze slabé korelace Z_i s proměnnou podpory T_i, dojde k zvýšení standardní chyby odhadu modelu z důvodu snížení přesnosti měření předpokládaných dopadů. Vzhledem k tomu, že nejsou dodrženy podmínky modelu, může dojít i k asymptotickému zkreslení odhadu modelu. Lze říci, že čím menší je korelace Z_i a T_i, tím vetší je asymptotické zkreslení odhadu *β*. Testování slabých instrumentů je však kvantitativně velmi problematické a odůvodnění je založena vědomostech o programu a účastech.

Dalšími nevýhodami jsou statistická vydatnost v případě slabého predikátoru a nemožnost vhodně otestovat, zda se jedná opravdu o instrumentální proměnnou.

Instrumentální proměnné jsou užitečné v experimentech, kdy z praktických nebo etických důvodů, není plně dodržováno rozdělení na podpořenou a kontrolní skupinu. Některé podpořené subjekty mohou z podpory vystoupit a některé subjekty z kontrolní skupiny se mohou do podpory zapojit.

Využitelnost pro TAČR

Z výše uvedených důvodů metodu instrumentálních proměnných pro využití agenturou TAČR nedoporučujeme. Největší nevýhodou této metody je obtížné nalezení vhodného instrument, který by měl splňovat podmínku exogenity. Testování jeho exogenity je navíc zatíženo subjektivitou.

3.5 Regression Discontinuity

Regresion Discontinuity Design (RD) byl poprvé představen D. L. Thistlethwaitem a D. T. Campbellem. Využitelnost této metody spočívá v předpokladu existence určitého pravidla, jehož pomocí lze subjekty rozdělit do dvou skupin. Tyto skupiny jsou tvořeny jednak subjekty nalézajícími se pod (či naopak nad) určitou hranicí klasifikovanými jakožto způsobilé pro podporu a naopak. Odhad dopadů pomocí metody je pak založen na porovnání podpořených a nepodpořených subjektů nalézajících se v blízkosti této hranice.

Obrázek 3: Výstupní proměnná před a po dotaci

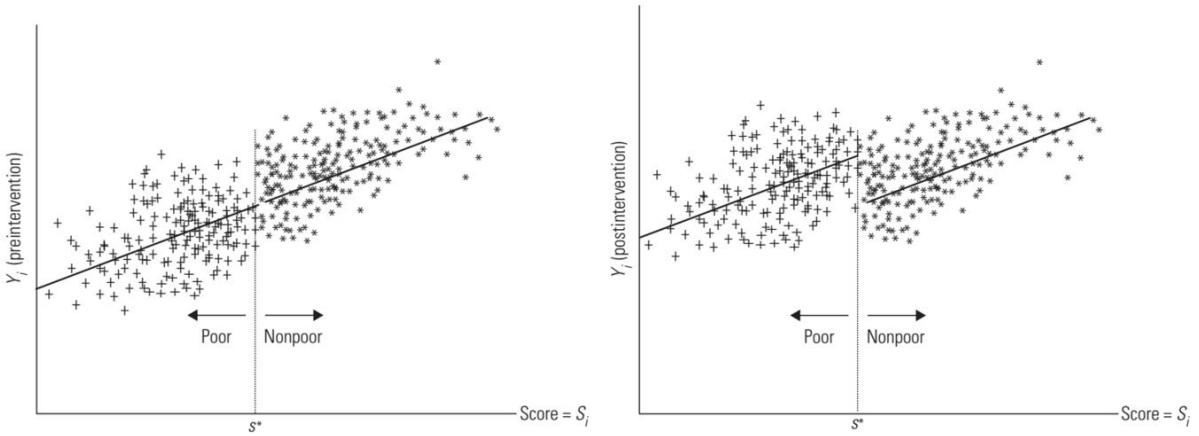

Zdroj: Shahidur 2010

Subjekty nalézající se v této oblasti jsou si podobné z hlediska posuzovaných kritérií. Metoda vyžaduje splnění několika kritérií, především pak:

1. subjekty musí být vybírány s ohledem na zvolenou hranici a
2. subjekty nesmí být schopny manipulovat se svou polohou vzhledem ke zvolené hranici.

Ideálně by měla být splněna tzv. ostrá diskontinuita intervence okolo hranice, kdy na jedné straně hranice pouze podpořené subjekty a na druhé naopak. V takovém případě je pravděpodobnost podpoření subjektu na jedné straně hranice rovna 1 a na druhé 0. V praxi však tato situace nastává velmi zřídka.

Při aplikaci metody tedy musíme nejdříve specifikovat proměnné pro výběr a dále nalézt vhodnou hranici určující způsobilost k podpoře. Pro nalezení subjektů, které budou vstupovat do analýzy, je nutné stanovit interval okolo dané hranice. Subjekty uvnitř tohoto intervalu budou následně využity pro analýzu. Dále je nutné dobře a přesně definovat proměnnou, pomocí které budeme dále hodnotit dopad dotace.

Velkým problémem této metody je nedostatečný počet pozorování v okolí zvolené hranice. Řešení se nabízí v podobě rozšíření pásma a zahrnutí dalších subjektů, čímž však dochází ke zkreslení výsledků. Z toho vyplývá, že metoda je velmi náročná na data z hlediska počtu subjektů splňující zadané podmínky. Další nevýhodou metody je, že odhadnutý dopad je interpretovatelný jen v okolí zvolené hranice. V neposlední době musí být brán zřetel i na situaci, kdy u subjektů dochází ke změnám od zvolené hranice, což může vést k znemožnění hodnocení dopadů. Na druhou strana metoda neklade žádné další předpoklady.

Využitelnost pro TAČR

Z důvodu problematické volby klasifikačního kritéria a datové náročnosti metody nevidíme tuto metodu jakožto vhodnou pro hodnocení dopadů finančních podpor poskytovaných TAČR.

4 Závěry a doporučení

Evaluace programů veřejné podpory je jejich klíčovou a neoddělitelnou součástí. Význam evaluací s ohledem na vývoj veřejných financí a snahu o snížení veřejného dluhu ve vyspělých ekonomikách pravděpodobně v čase poroste. Přestože existuje celé spektrum evaluačních metod a přístupů k hodnocení programů veřejné podpory, nelze v současnosti hovořit o zaběhnuté „nejlepší praxi“. Dá se říci, že zejména s ohledem na dostupnost dat a specifický charakter řady typů podpory, je v současnosti stále nejrozšířenější hodnocení pomocí tzv. case studies, doplněné o jednoduché analytické výstupy založené na tzv. monitorovacích indikátorech (např. výdaje na jedno nově vytvořené pracovní místo, čisté VaV výdaje soukromého subjektu vyvolané 1 korunou podpory apod.). Tyto jednoduché metody ale obvykle nenabízí komplexní pohled na efekt podpory, případně nabízí jen velmi zjednodušující pohled, kdy často může docházet k zahrnutí vnějších vlivů do zdánlivých efektů podpory. Nesprávně provedené hodnocení přitom může mít z hlediska efektivity vynakládání veřejných zdrojů dramatické důsledky – může dojít k zastavení programů, které jsou ve skutečnosti efektivní nebo naopak další podpoře aktivit, které jsou ve skutečnosti neefektivní.

V poslední době tak přirozeně dochází k růstu poptávky po evaluačních metodách, které jsou schopné podat přesnější a objektivnější výsledky, založené jak na kvalitativních, tak především kvantitativních metodách a „tvrdých“ datech. Tzv. kontrafaktuální analýza (CIE) je jedním z přístupů, který tyto možnosti nabízí. Její reálná využitelnost je ale velmi závislá na dostupnosti dostatečného množství dat a také schopnosti analytika metodu správně použít (zejména definovat tzv. covariates). CIE nabízí zhodnocení efektu podpory porovnáním podpořené a nepodpořené (kontrolní) skupiny, kdy sledujeme především tzv. ATET – tedy efekt na podpořenou skupinu. CIE je tedy reflexivní metoda, resp. přístup, kdy její přesnost je tím větší, čím podobnější jsou obě porovnávané skupiny. Čím homogennější jsou vzájemně obě skupiny, tím větší je redukce vnějších vlivů, které mohou ovlivnit výsledek podpory. Pro zajištění homogenity bývá často využívána metoda PSM (Propensity score matching). Zde je podstatná správná volba covariates, tedy faktorů, které mohou ovlivnit výstupní proměnnou a rozhodování subjektu o podpoře ale nejsou ovlivněny samotnou podporou. Jde jinými slovy o faktory, které popisují vnější prostředí a jejichž započtením eliminujeme, resp. minimalizujeme externí vlivy. Při ideální aplikaci pak sledujeme dvě skupiny subjektů, které jsou těmto vlivům vystaveny stejnou měrou. Výsledky párování, kdy existuje několik možných technik (nejčastěji je využívána technika nejbližšího souseda a Kernel matching), by neměly být diametrálně odlišné, resp. výsledky by měly být robustní vzhledem k použitým technikám párování. Vhodnost napárování a homogenitu skupin je pochopitelně třeba testovat (testy rovnováhy, tzv. common support, redukce biasu). Pokud testy ukáží nevhodnou volbu covariates (např. redukce biasu je nedostatečná), je třeba model redefinovat.

4.1 Doporučení pro Technologickou agenturu ČR

Pro účely TAČR je metoda CIE vhodná, především se jako vhodná jeví kombinace PSM s metodou difference in difference (DD). Tato kombinace na jedné straně zajišťuje homogenitu skupin (PSM), na

druhé straně potom díky DD dochází k eliminaci časově invariantní vlivů. Jak ukazují současné studie, jde o kombinaci, která přináší validní a efektivní odhady (Hirano, Imbens a Ridder 2003).
Pro aplikaci této evaluační metody je nicméně nutné splnit některé předpoklady.

V první řadě je nutné definovat cíl podpory a v souvislosti s ním i správně identifikovat očekávané výstupní indikátory. Tyto indikátory musí být měřitelné a musí mít jasnou vazbu na cíl programu. Například pokud je cílem programu konkurenceschopnost, je třeba nejprve jasně vymezit, co se konkurenceschopností myslí a jaké indikátory budeme sledovat. Typicky chybným indikátorem je počet nově vytvořených pracovních míst. Je sice pravděpodobné, že konkurenceschopnější firmy vytváří nová pracovní místa, nicméně to automaticky neznamená, že nová místa zajistí vyšší konkurenceschopnost. Kauzalita totiž směřuje od konkurenceschopnosti k vytvoření nových míst a nikoli naopak. Správná definice výstupních indikátorů je tak zcela klíčová pro konečný efekt programu. I přesto, že se program může jevit, po korektní aplikaci CIE, jako úspěšný, ve skutečnosti může být jeho výsledkem něco jiného, než jeho poskytovatel/zadavatel zamýšlel. Volba výstupních indikátorů daného programu by měla proběhnout na základě intenzivní diskuze mezi zadavatelem, potenciálně dotčenými subjekty a externími odborníky.

Za druhé je nutné zajistit dostatečný objem relevantních dat. Zde se lze domnívat, že má zadavatel poměrně silnou vyjednávací pozici vůči potenciálním uchazečům o podporu v programu. Součástí žádosti tak může být i povinnost vyplnění definovaných požadavků na data, a to jak před podporou (v době podání žádosti), tak v průběhu podpory (monitoring) a po uzavření projektu. Pochopitelně je třeba dbát na to, aby nebyly dotčeny zákonné normy (zejm. na ochranu údajů) a pro žadatele neznamenala datová povinnost nadměrnou administrativní zátěž.

5 Praktická ukázka uplatnění metodiky CIE pro Technologickou agenturu ČR

V této části předvedeme praktickou ukázku kontrafaktuální analýzy. Je třeba předeslat, že přestože v této ukázce je pracováno s reálnými daty a tvoříme určité závěry, má ukázka především edukativní cíl. Je to dáno zejména kvalitou a dostupností dat za současných podmínek. Především jako jeden z primárních datových zdrojů o podpoře VaV byla použita databáze ISVaV, kdy shromážděná data byla z různých programů s různě specifikovanými cíli (z databáze tedy není možné zjistit původní cíl podpory). Základní stavební kámen analýzy – definice cíle podpory, je tak bohužel nejasný a bude definován pouze na základě uvážení zpracovatelů této metodiky. Dále nejsou z této databáze známy neúspěšní žadatelé o podporu. To znesnadňuje správné definování kontrolní skupiny, která by se měla sestávat ze subjektů s podobnou motivací ve vztahu k participaci na podpoře. Tento problém byl do určité míry ošetřen tím, že za kontrolní skupinu byly zvoleny nepodpoření žadatelé z programu TAČR Alfa. Nicméně tento program probíhal v jiném časovém období a byl specificky zaměřen. V následujícím textu budeme sledovat navrhovaný postup přípravy a implementace CIE (Obrázek 1), přičemž se z pochopitelných důvodů soustředíme především na aplikaci jednotlivých metod a jejich výsledky. Monitoring je vypuštěn.

5.1 Definice cíle programu, časový rámec

Jak již bylo uvedeno výše, definice cíle je v tomto případě obtížná, neboť vycházíme z databáze ISVaV, která sdružuje data o podpoře VaV bez ohledu na zdroj, resp. cíl podpory. V databázi se nachází jak veřejné, tak soukromé subjekty podpořené v letech 2007 – 2010. U veřejných subjektů lze nicméně předpokládat jiný režim a jiné cíle, než u subjektů soukromých. Jejich hodnocení je dle našeho názoru třeba provádět odděleně, na základě odlišné metodiky, než je zde navrhována (IPN metodika). Zde navrhovaná metodika se tedy týká hodnocení **soukromých subjektů.** Vzhledem k absenci jednotného cíle definujeme pro účely této ukázky dva dílčí cíle. Prvním cílem je **konkurenceschopnost**, druhým cílem je **inovační aktivita**. Oba cíle jsou z hlediska rozvoje ekonomiky nepochybně klíčové, objevují se v různých podobách v řadě programů veřejné podpory, včetně podpory VaV (např. Program na podporu aplikovaného výzkumu a experimentálního vývoje ALFA a Program Centra kompetence). Z hlediska časového rámce bylo za období podpory označeno období 2007 – 2010 (přestože projekty nebyly vždy stejně dlouhé, jde o nutnou a standardní simplifikaci), období před podporou potom 2004 – 2006 a po podpoře 2011 – 2012. Je pochopitelně možné období zvolit delší (zejména období po podpoře), nicméně to nebylo v době zpracování metodiky vzhledem k dostupnosti dat možné. Navíc tato skutečnost nijak významně neovlivní cíl metodiky, kterým je seznámit uživatele s metodou CIE.

5.2 Definice výstupních indikátorů

Výstupními indikátory pro konkurenceschopnost **bude růst přidané hodnoty a změna přidané hodnoty na osobní náklady.** Jde o průměrné hodnoty sledovaných subjektů v období po podpoře tj.

průměrné hodnoty z let 2011-2012. Data o počtu zaměstnaných nebyla z použitých datových zdrojů dostupná, ale lze pochopitelně uvažovat i o tomto ukazateli. Výstupním ukazatelem pro inovační aktivitu potom bude **počet patentů**. V tomto případě zahrneme do výstupních hodnot i hodnoty z let podpory 2007-2010, neboť patenty mohly vznikat díky podpoře již v průběhu podpory.

5.3 Definice metody, volba covariates a struktury modelu.

Vzhledem k tomu, že jde o metodiku, budou aplikovány všechny výše popsané metody. A to i přesto, že metoda náhodného výběru by zřejmě v normální aplikaci nepřipadala v úvahu, a to zejména proto, že participace v programu podpory není náhodná. Pro covariates, které využijeme především u PSM, byly v první fázi zvoleny následující proměnné (hodnota proměnných byla průměrnou hodnotou v období před podporou – 2004 až 2006):

- **Velikost (size)**. Firmy budou mít charakteristiku mikro (do 10 zaměstnanců), malé (do 49 zaměstnanců), střední (50-250) a velké 250+ zaměstnanců. Tato definice odpovídá Eurostatu.[7]
- **Stáří společnosti (age).** Stáří společnosti měřené v měsících k 31.12.2006 – k začátku období podpory.
- **Majetek.** Hmotný investiční majetek, opět průměrná hodnota subjektu za období.
- **CZ NACE Rev1.1.** Příslušnost subjektu k dané skupině (A-Q) dle hlavní ekonomické činnosti. Jde o dummy (1-0) proměnnou.
- **Geografická poloha**. Sídlo subjektu dle NUTS3. Jde o dummy (1-0) proměnnou
- **Přidaná hodnota na osobní náklady.** Jako covariate v případě inovační aktivity. Průměrná hodnota subjektu za období.
- **Patenty**. Jako covariate v případě konkurenceschopnosti v období 2000-2006. Opět předpokládáme, že patentová aktivita vyžaduje delší časový horizont – jak dopředně, tak zpětně. Jde o dummy (1-0) proměnnou.

Pochopitelně by bylo možné uvažovat o dalších vhodných proměnných, a to jak na straně covariates, tak na straně výstupních indikátorů. Typicky diskutovanou proměnnou jsou výdaje na vědu a výzkum. Bohužel individualizovaná data o výdajích na vědu a výzkum, která sbírá ČSÚ, nejsou veřejně dostupná (a to ani na vyžádání). Poněkud diskutabilní je navíc podle názoru autorů této metodiky i jejich pravdivost. Další možnou proměnnou je počet zaměstnanců, tato proměnná by zřejmě mohla být zařazena při využití dalšího datového zdroje. Z hlediska cíle metodiky, ale i vzhledem k zařazení osobních nákladů, to nepovažují autoři za zásadní. Ke statistickému zpracování byl použit program STATA, výstupy jsou záměrně reprezentovány v podobě, ve které je program uvádí, a to i z edukativních důvodů (je možné tréninkové ověření výsledků pracovníkem TAČR).

---

[7] Přesněji by měl být zařazen také obrat.

5.4 Sběr dat, analýza datového zdroje a redefinice modelu.

Datový zdroj byl vytvořen kombinací několika databází. Data o podpoře a její výši byla získána z již zmiňované databáze ISVaV (podpořené subjekty včetně identifikátoru IČO). Ostatní data s výjimkou patentů byla získána z databáze Bisnode (jde především o finanční data, která jsou získávána de facto z výročních zpráv). Data o patentech byla získána z Patentového úřadu. Datový zdroj je poskytnut agentuře TAČR spolu s metodikou jako podpůrný materiál pro případné vzdělávání vlastních pracovníků.

Původní skupina sledovaných subjektů se sestávala z 555 podpořených subjektů a 1074 nepodpořených žadatelů (kontrolní skupina). Z hlediska dostupnosti dat výstupních indikátorů konkurenceschopnosti bylo konstatováno, že vzorek byl značně redukován – data nebyla dostupná u více než poloviny subjektů. Podpořená skupina tak byla redukována na 277 subjektů (49%) a kontrolní na 510 subjektů (47,5%). Bohužel alternativní indikátor v tomto případě není, resp. zpracovatelé metodiky si nejsou vědomi vhodnějšího indikátoru. Zařazení covariates vzorek dále redukovalo. Proměnná HIM redukuje podpořenou skupinu na 261 subjektů, kontrolní skupinu potom na 493 subjektů. Velikost, stáří, patenty ani NACE vzorek nijak významně neredukovaly. U proměnné NACE nicméně bylo zjištěno, že značná část subjektů (u podpořené skupiny více než 80%, u kontrolní skupiny téměř 70%) spadá do kategorií C (zpracovatelský průmysl), J (Informační a komunikační činnosti) nebo M (profesní, vědecké a technické činnosti). U některých kategorií nebyli evidováni žádní žadatelé, u řady kategorií se jednalo o jednotky. Pro další účely proto byly využity pouze tyto kategorie, resp. činnosti mimo tyto kategorie mají ve všech kategoriích C, J a M hodnotu 0. Geografická poloha podle sídla NUTS3 opět výrazně redukuje vzorek (o dalších 10 procentních bodů u obou skupin). Lze přitom předpokládat, že v případě ČR nejsou regionální disparity z hlediska podpořených subjektů zásadní proměnnou. Z tohoto důvodu byla tato proměnná z modelu vypuštěna. Nicméně pokud by byl datový vzorek vydatnější, lze uvažovat o jejím zařazení. Konečný vzorek měl 747 pozorování, 258 subjektů v podpořené skupině a 489 v kontrolní skupině. Konečná specifikace proměnných a jejich základní statistika (střední hodnoty) tak vypadá takto:

Treat - dummy 0-1 proměnná podpory (0 pro kontrolní skupinu, 1 pro podpořenou skupinu)

PH46, resp. lnPH46 - přidaná hodnota v letech 2004-2006 (v tisících Kč cen běžného roku)

PH1112, resp. lnPH1112 - přidaná hodnota v letech 2011-2012 (v tisících Kč cen běžného roku)

Phon46 - přidaná hodnota na korunu osobních nákladů v letech 2004-2006

Phon1112 - přidaná hodnota na korunu osobních nákladů v letech 2011-2012

Patbt - existence podaných patentů v období před podporou (2000-2006). 0-1

Patat - existence podaných patentů v období během podpory a po podpoře (2007-2014). 0-1

Size - velikost subjektu v roce 2006. 0-1 proměnná v kategoriích **sizemc** (do 10 zaměstnanců), **sizesm** (do 49 zaměstnanců), **sizeme** (50-250) a **sizelg** 250+ zaměstnanců.

Age - stáří společnosti od založení do 31. 12. 2006 v měsících

TAS46, resp. ln TAS46 - hmotný investiční majetek v letech 2004-2006 (v tisících Kč cen běžného roku)

Ind - příslušnost k danému odvětví ekonomických činností (CZ NACE). 0-1 proměnná v kategoriích **indc** (zpracovatelský průmysl), **indj** (informační a komunikační činnosti) a **indm** (profesní, vědecké a technické činnosti).

Obrázek 4: Průměrné hodnoty

Summary statistics: mean
by categories of: treat (treat)

treat	age	patbt	patat	TAS46	indc	indj	indm
0	123.0225	.0102249	.0327198	238279.5	.4376278	.1104294	.1247444
1	120.5504	.0348837	.1550388	147592.4	.5232558	.0930233	.2286822
Total	122.1687	.0187416	.0749665	206957.8	.4672021	.1044177	.1606426

treat	PH46	PH1112	phon46	phon1112	sizemc	sizesm	sizeme
0	100178.7	141809.6	1.921867	1.705732	.1247444	.3496933	.402863
1	111775.6	143029	1.56604	1.43825	.0968992	.3023256	.4302326
Total	104184.1	142230.8	1.798971	1.613349	.1151272	.3333333	.4123159

treat	sizelg
0	.1226994
1	.1705426
Total	.1392236

Statistika středních hodnot ukazuje na poměrně dobrou shodu obou skupin. Již z této úvodní statistiky jsou nicméně zřejmé některé odlišnosti. Například je dobře vidět, že v průměru podpořené subjekty vykazovaly v období před udělením podpory relativně nižší inovační aktivitu (počet patentů), zatímco v období podpory a po podpoře se situace obrátila – inovační aktivita podpořených firem výrazně převýšila aktivitu nepodpořených firem. Nepodpořené firmy vykazovaly relativně vyšší hodnotu hmotného majetku v období před podporou a také relativně lepší ukazatel konkurenceschopnosti (podíl na osobních nákladech), a to jak v období před podporou, tak po podpoře. V tomto ukazateli nastal pokles u obou skupin, velmi pravděpodobně ve spojitosti s proběhlou recesí. Podpořené firmy vykazují relativně vyšší podíl firem v odvětví profesních, vědeckých a technických činností (M). U proměnných hmotný investiční majetek a přidaná hodnota se dá očekávat poměrně značné variační rozpětí, tyto proměnné proto budou pro další aplikace logaritmovány (ln před zkratkou proměnné).

5.5 Implementace CIE – náhodný výběr

Jak bylo uvedeno výše, nebyly podpořené subjekty vybrány náhodně. Nicméně pro účely demonstrace metody na okamžik uvažujme tak, že jde o náhodný výběr (jak u podpořené, tak u kontrolní skupiny).

Náhodný výběr – jednoduché určení ATET – diference v proměnných po podpoře

Nejjednodušším způsobem, jak určit efekt podpory je zjistit jednoduše rozdíl dané výstupní veličiny v období po podpoře mezi kontrolní a podpořenou skupinou. Tento postup samozřejmě nereflektuje původní rozdíly ve výstupních proměnných a může být proto z hlediska závěrů zkreslený. Lepším přístupem je aplikace difference in difference – viz dále. Po aplikaci tohoto zjednodušeného postupu na výstupní proměnné získáváme následující výstupy.

Pro charakteristiky konkurenceschopnosti (PH1112, phon1112):

Obrázek 5: ATET PH1112 (Přidaná hodnota v letech 2011 a 2012)

```
Two-sample t test with equal variances
------------------------------------------------------------------------------
   Group |     Obs        Mean    Std. Err.   Std. Dev.   [95% Conf. Interval]
---------+--------------------------------------------------------------------
       0 |     489    10.30244    .0748981    1.656248    10.15528    10.44961
       1 |     258    10.49209     .100601    1.615892    10.29398    10.69019
---------+--------------------------------------------------------------------
combined |     747    10.36794    .0601441    1.643816    10.24987    10.48601
---------+--------------------------------------------------------------------
    diff |           -.1896416     .126382               -.4377488    .0584656
------------------------------------------------------------------------------
    diff = mean(0) - mean(1)                                      t =  -1.5005
Ho: diff = 0                                     degrees of freedom =      745

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.0669         Pr(|T| > |t|) = 0.1339          Pr(T > t) = 0.9331
```

Obrázek 6: ATET phon1112 (Přidaná hodnota na korunu osobních nákladů v letech 2011 a 2012)

```
Two-sample t test with equal variances
------------------------------------------------------------------------------
   Group |     Obs        Mean    Std. Err.   Std. Dev.   [95% Conf. Interval]
---------+--------------------------------------------------------------------
       0 |     489    1.705732    .0751911    1.662726    1.557994    1.853471
       1 |     258     1.43825    .0502493    .8071225    1.339297    1.537203
---------+--------------------------------------------------------------------
combined |     747    1.613349    .0523752    1.431482    1.510529    1.716169
---------+--------------------------------------------------------------------
    diff |            .2674823    .1097867                .0519541    .4830105
------------------------------------------------------------------------------
    diff = mean(0) - mean(1)                                      t =   2.4364
Ho: diff = 0                                     degrees of freedom =      745

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.9925         Pr(|T| > |t|) = 0.0151          Pr(T > t) = 0.0075
```

Pro charakteristiku inovační aktivity (patat):

Obrázek 7: ATET patat (Patenty v období podpory a po podpoře)

```
Two-sample t test with equal variances
```

Group	Obs	Mean	Std. Err.	Std. Dev.	[95% Conf.	Interval]
0	489	.0327198	.0080533	.1780845	.0168965	.0485432
1	258	.1550388	.0225773	.3626451	.1105787	.1994988
combined	747	.0749665	.0096415	.2635138	.0560389	.0938942
diff		-.1223189	.0197893		-.1611684	-.0834695

```
    diff = mean(0) - mean(1)                                      t =  -6.1811
Ho: diff = 0                                     degrees of freedom =      745

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.0000         Pr(|T| > |t|) = 0.0000          Pr(T > t) = 1.0000
```

Z výsledků je patrné, že co se týče konkurenceschopnosti, mají podpořené subjekty vyšší přidanou hodnotu, než subjekty nepodpořené (v průměru o 6,2 mil Kč, hladina významnosti je zde o něco nižší, než obvyklých 95% - 93,6%), nicméně z hlediska poměru přidané hodnoty k osobním nákladům je situace opačná – nepodpořené subjekty jsou zhruba o 18,5% efektivnější. U patentů by se potom situace mohla zdát jako jednoznačná – inovační aktivita podpořených firem byla výrazně vyšší, než u nepodpořených firem (zhruba pětinásobně). Tyto závěry jsou nicméně zkresleny (odhlédneme-li od toho, že při přidělování podpory nejde o náhodný výběr) tím, že metoda nebere v úvahu ani výchozí situaci ani další proměnné, které mohou výstup ovlivnit. Jde o nejjednodušší ale také pravděpodobně nejméně přesnou metodu odhadu.

Náhodný výběr s double difference (ATET)

Lepším přístupem k odhadu ATET, který bere v úvahu hodnoty výstupních proměnných v období před podporou, je výše popsaná metoda double difference (nebo difference in difference – DD). Výsledky jednoduchého odhadu ukazují následující tabulky

Obrázek 8: DD ATET – přidaná hodnota

Two-sample t test with equal variances

Group	Obs	Mean	Std. Err.	Std. Dev.	[95% Conf.	Interval]
0	489	.541725	.0399155	.8826651	.4632976	.6201525
1	258	.4287132	.0562514	.9035319	.3179407	.5394856
combined	747	.5026928	.032598	.8909463	.438698	.5666876
diff		.1130118	.0684773		-.0214195	.2474432

```
    diff = mean(0) - mean(1)                                      t =   1.6504
Ho: diff = 0                                     degrees of freedom =      745

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.9504         Pr(|T| > |t|) = 0.0993          Pr(T > t) = 0.0496
```

Obrázek 9: DD ATET – přidaná hodnota na korunu mzdových nákladů

Two-sample t test with equal variances

Group	Obs	Mean	Std. Err.	Std. Dev.	[95% Conf.	Interval]
0	489	-.2161342	.0775289	1.714422	-.3684657	-.0638026
1	258	-.1277902	.0572401	.9194123	-.2405096	-.0150708
combined	747	-.1856218	.0544623	1.488525	-.2925393	-.0787042
diff		-.088344	.1145698		-.313262	.1365741

```
    diff = mean(0) - mean(1)                                      t =  -0.7711
Ho: diff = 0                                     degrees of freedom =      745

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.2204         Pr(|T| > |t|) = 0.4409          Pr(T > t) = 0.7796
```

Obrázek 10: DD ATET – patenty

```
Two-sample t test with equal variances
```

Group	Obs	Mean	Std. Err.	Std. Dev.	[95% Conf.	Interval]
0	489	.0224949	.0078627	.1738696	.007046	.0379437
1	258	.120155	.0210123	.3375074	.0787768	.1615332
combined	747	.0562249	.0090497	.2473412	.0384589	.0739909
diff		-.0976602	.018706		-.1343829	-.0609374

```
    diff = mean(0) - mean(1)                                      t =  -5.2208
Ho: diff = 0                                     degrees of freedom =      745

    Ha: diff < 0                 Ha: diff != 0                 Ha: diff > 0
 Pr(T < t) = 0.0000         Pr(|T| > |t|) = 0.0000          Pr(T > t) = 1.0000
```

Z odhadu pomocí difference in difference je zřejmé, že zatímco v případě patentů se inovační aktivita podpořených firem významně zvýšila (v průměru zhruba každá desátá podpořená firma přišla s novým patentem, zatímco u nepodpořených firem to byly 2 ze 100) ve srovnání s nepodpořenými firmami, nicméně z hlediska konkurenceschopnosti je situace spíše opačná, resp. nejednoznačná. U ukazatele přidané hodnoty došlo k vyššímu nárůstu u nepodpořených firem, než u firem podpořených (62% proti 54% nárůstu PH v běžných cenách), u ukazatele podílu přidané hodnoty na korunu mzdových nákladů je výsledek statisticky nevýznamný, nelze tedy konstatovat ani pozitivní ani negativní rozdíl mezi oběma skupinami.

Náhodný výběr - regrese s covariates

Stejné výsledky jako u předchozích odhadů získáme aplikací jednoduchého regresního modelu, kdy jedinou vysvětlující proměnnou je participace na podpoře ***treat***. V dalším postupu již zahrneme kromě samotné výstupní proměnné (resp. její změny) i covariates, tedy proměnné, které v regresním modelu fungují de facto jako kontrolní. Jejich zahrnutí by mělo výrazně přispět ke kvalitě odhadovaného výstupu, neboť bereme do úvahy vlivy, které mohly ovlivnit výstup[8].

[8] Proměnná sizemc, tedy firmy velikosti mikro, byla vyřazena z důvodu dokonalé kolinearity, resp. vzájemné exkluze s dalšími proměnnými velikostní kategorie size. Odhad byl proveden s robustními

Obrázek 11: Odhad regresí - přidaná hodnota

```
Linear regression                                      Number of obs =     747
                                                       F( 10,   736) =    9.47
                                                       Prob > F      =  0.0000
                                                       R-squared     =  0.1608
                                                       Root MSE      =  .82168
```

dlnph	Coef.	Robust Std. Err.	t	P>|t|	[95% Conf.	Interval]
patbt	-.2146042	.1343542	-1.60	0.111	-.4783674	.0491589
treat	-.1074135	.0649094	-1.65	0.098	-.2348431	.0200162
sizesm	.4058309	.1357384	2.99	0.003	.1393502	.6723115
sizeme	.8773929	.144321	6.08	0.000	.594063	1.160723
sizelg	1.172902	.1907793	6.15	0.000	.7983658	1.547439
indc	-.0754803	.0785546	-0.96	0.337	-.2296981	.0787376
indj	-.0658652	.1281688	-0.51	0.607	-.3174853	.1857549
indm	.0188318	.1083583	0.17	0.862	-.1938963	.2315599
lnTAS46	-.1538968	.0223572	-6.88	0.000	-.1977884	-.1100053
age	-.0023171	.0006857	-3.38	0.001	-.0036634	-.0009709
_cons	1.595633	.2373068	6.72	0.000	1.129754	2.061512

Obrázek 12: Odhad regresí - přidaná hodnota na korunu mzdových nákladů

```
Linear regression                                      Number of obs =     747
                                                       F( 10,   736) =    1.01
                                                       Prob > F      =  0.4354
                                                       R-squared     =  0.0044
                                                       Root MSE      =  1.4953
```

dphon	Coef.	Robust Std. Err.	t	P>|t|	[95% Conf.	Interval]
patbt	-.4023814	.2738092	-1.47	0.142	-.9399214	.1351587
treat	.076564	.0934537	0.82	0.413	-.1069037	.2600317
sizesm	-.0055428	.3052161	-0.02	0.986	-.6047408	.5936551
sizeme	.0318352	.3245715	0.10	0.922	-.6053612	.6690316
sizelg	.0537319	.3775275	0.14	0.887	-.6874271	.794891
indc	.0608636	.1502661	0.41	0.686	-.2341377	.3558649
indj	-.0564402	.1636841	-0.34	0.730	-.3777836	.2649032
indm	.1308822	.1788506	0.73	0.465	-.220236	.4820004
lnTAS46	-.0002434	.0459757	-0.01	0.996	-.0905025	.0900158
age	.0006875	.0008597	0.80	0.424	-.0010004	.0023753
_cons	-.3486391	.4909117	-0.71	0.478	-1.312393	.6151151

Obrázek 13: Odhad regresí - patenty

```
Linear regression                                      Number of obs =     747
                                                       F( 10,   736) =    3.97
                                                       Prob > F      =  0.0000
                                                       R-squared     =  0.0520
                                                       Root MSE      =  .24246
```

dpat	Coef.	Robust Std. Err.	t	P>|t|	[95% Conf.	Interval]
phon46	-.0006906	.0025926	-0.27	0.790	-.0057804	.0043993
treat	.0884576	.0222109	3.98	0.000	.0448532	.1320619
sizesm	.014979	.0230045	0.65	0.515	-.0301832	.0601413
sizeme	.0156518	.026433	0.59	0.554	-.0362412	.0675449
sizelg	-.0265565	.0439315	-0.60	0.546	-.1128025	.0596896
indc	.0438261	.0203439	2.15	0.032	.0038871	.0837651
indj	-.0193697	.0163164	-1.19	0.236	-.051402	.0126626
indm	.0451989	.0300621	1.50	0.133	-.0138187	.1042166
lnTAS46	.004926	.0037767	1.30	0.193	-.0024885	.0123405
age	.0001272	.0001033	1.23	0.219	-.0000756	.00033
_cons	-.0665737	.0360156	-1.85	0.065	-.1372793	.0041319

Z výše uvedených odhadů se můžeme domnívat, že podpora VaV se sice odrazila ve vyšší inovační aktivitě, nicméně neměla žádný dopad na konkurenceschopnost ve smyslu růstu přidané hodnoty nebo změny přidané hodnoty na korunu osobních nákladů. Mohli bychom se tedy domnívat, že podpora VaV je úspěšná ve smyslu podpory zvýšené inovační aktivity (více patentů), nicméně vazba mezi touto aktivitou a vyšší konkurenceschopností je přinejmenším diskutabilní. Závěry jsou nicméně pouze cvičné – jak již bylo několikrát zmíněno, nejde o náhodný výběr a použitá metoda tak není zcela vhodná.

5.6 Implementace CIE – PSM

5.6.1 Konkurenceschopnost

Vzhledem k tomu, že přidělení podpory neprobíhalo náhodně, není možné výše zvolenou metodu náhodného výběru fakticky použít. Naopak jako vhodná se jeví metoda PSM. V prvním kroku je třeba určit covariates a strukturu modelu – to jsme provedli již na začátku této praktické části. Druhým krokem je odhadnout logistický, případně probabilistický (probit) model, určení skóre a provedení testu rovnováhy. Výsledky logistické regrese aplikované na náš vzorek pro hodnocení dopadu VaV podpory na **konkurenceschopnost** ukazuje následující výstup (jde o výstup ze statistického software STATA)

Obrázek 14: PSM – odhad propensity score

```
The treatment is treat

      treat |      Freq.     Percent        Cum.
------------+-----------------------------------
          0 |        489       65.46       65.46
          1 |        258       34.54      100.00
------------+-----------------------------------
      Total |        747      100.00


Estimation of the propensity score

Iteration 0:   log likelihood = -481.47186
Iteration 1:   log likelihood = -458.00352
Iteration 2:   log likelihood = -457.88482
Iteration 3:   log likelihood =  -457.8848

Probit regression                                 Number of obs   =        747
                                                  LR chi2(9)      =      47.17
                                                  Prob > chi2     =     0.0000
Log likelihood =  -457.8848                       Pseudo R2       =     0.0490

------------------------------------------------------------------------------
       treat |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         age |  -.0008259   .0008963    -0.92   0.357    -.0025827    .0009308
      sizemc |  -.1255027   .1972192    -0.64   0.525    -.5120453    .2610399
      sizesm |   -.005758   .1276009    -0.05   0.964    -.2558512    .2443351
      sizelg |   .0611718   .1625404     0.38   0.707    -.2574016    .3797452
     lnTAS46 |   .0389849   .0280391     1.39   0.164    -.0159707    .0939404
        indc |   .5232333   .1256817     4.16   0.000     .2769016     .769565
        indj |    .418505   .1849984     2.26   0.024     .0559149    .7810951
        indm |   .9132694   .1580983     5.78   0.000     .6034024    1.223136
       patbt |   .7399839   .3608572     2.05   0.040     .0327169    1.447251
       _cons |   -1.11212   .3101083    -3.59   0.000    -1.719921    -.504319
------------------------------------------------------------------------------
```

Z výstupu je zřejmé, že získání podpory je pozitivně ovlivněno daným odvětvím. Jak jsme se již mohli domnívat ze základního statistického popisu dat, pokud žadatel náleží do kategorie C, J nebo M, je jeho pravděpodobnost získání VaV podpory vyšší. Největší efekt má přitom kategorie M, tedy

profesní, vědecké a technické činnosti. Zároveň můžeme konstatovat, že z ostatních proměnných má pozitivní vliv ještě proměnná patbt – tedy skutečnost, že firma přihlásila patent před podáním žádosti o podporu, zvyšuje její pravděpodobnost získání podpory. Ani velikost ani stáří společnosti se neukázaly z hlediska pravděpodobnosti dosažení podpory jako statisticky významné proměnné.

V dalším kroku je nutné provést balanční testy (testy rovnováhy). Výstup tohoto testu spolu s odhadnutým intervalem *common support* ukazuje následující obrázek.

Obrázek 15: Common support a test rovnováhy

```
Note: the common support option has been selected
The region of common support is [.11499222, .80916549]


Description of the estimated propensity score
in region of common support

                 Estimated propensity score
-------------------------------------------------------------
      Percentiles      Smallest
 1%     .1345816       .1149922
 5%     .1701377       .1150908
10%      .189123       .1196796       Obs                 742
25%     .2457344       .1197271       Sum of Wgt.         742

50%     .3645101                      Mean           .3472651
                        Largest       Std. Dev.      .1157696
75%     .4122944       .7446452
90%     .4983521       .7531416       Variance       .0134026
95%     .5217274       .7684729       Skewness       .2128478
99%     .6678591       .8091655       Kurtosis       3.163097


*****************************************************
Step 1: Identification of the optimal number of blocks
Use option detail if you want more detailed output
*****************************************************


The final number of blocks is 5

This number of blocks ensures that the mean propensity score
is not different for treated and controls in each blocks


*********************************************************
Step 2: Test of balancing property of the propensity score
Use option detail if you want more detailed output
*********************************************************


The balancing property is satisfied


This table shows the inferior bound, the number of treated
and the number of controls for each block
```

Inferior of block of pscore	treat 0	1	Total
.1149922	88	22	110
.2	284	129	413
.4	110	100	210
.6	2	6	8
.8	0	1	1
Total	484	258	742

```
Note: the common support option has been selected
```

Náš odhad splňuje test rovnováhy, bylo celkově identifikováno 5 bloků.

Párování a odhady efektů podpory - konkurenceschopnost

Párování a výsledný efekt podpory lze, jak již bylo vysvětleno v teoretické části, provést pomocí celé řady metod. V rámci této metodiky se soustředíme na metody, které byly podrobněji popsány v teoretické části, a které se využívají nejčastěji. Budeme se přitom soustředit na efekt podpory na podpořenou skupinu tj. ATET. Zároveň budeme sledovat výstupní proměnné v jejich změnách, tedy aplikovat kombinaci difference in difference a PSM. Budeme přitom postupovat tak, že nejprve aplikujeme všechny metody na růst přidané hodnoty a poté na změnu přidané hodnoty na korunu osobních nákladů. Tento postup je volen zejména z důvodu přehlednosti a zjištění robustnosti výsledků – výsledky jsou vnímány jako robustní, pokud všechny metody vedou k podobnému odhadu podpory (Shahidur 2010).

5.6.2 Růst přidané hodnoty

Metoda nejbližšího souseda (*nearest neighbour* – NN).

Obrázek 16: Metoda nejbližšího souseda - průměrné hodnoty

```
ATT estimation with Nearest Neighbor Matching method
(random draw version)
Analytical standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
258	168	-0.150	0.098	-1.525

```
Note: the numbers of treated and controls refer to actual
nearest neighbour matches
```

Caliper a radius matching.

Byl zvolen radius 0.01.

Obrázek 17: Caliper a radius matching - průměrné hodnoty

```
ATT estimation with the Radius Matching method
Analytical standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
218	337	-0.047	0.079	-0.599

```
Note: the numbers of treated and controls refer to actual
matches within radius
```

Stratifikace a intervalové párování (*interval matching*).

Obrázek 18: Stratifikace a intervalové párování - průměrné hodnoty

```
ATT estimation with the Stratification method
Analytical standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
257	485	-0.108	0.071	-1.519

Kernel matching a local linear matching (LLM).

Obrázek 19: Kernel matching a local linear matching - průměrné hodnoty

```
ATT estimation with the Kernel Matching method
Bootstrapped standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
258	484	-0.093	0.064	-1.457

Ve všech případech je evidentní, že podpora neměla pozitivní efekt na růst přidané hodnoty u podpořených firem ve srovnání s firmami nepodpořenými. Efekt byl spíše opačný, přestože vzhledem k hodnotám t-statistik jej nelze považovat na 95% hladině významnosti za statisticky

významný. Na 90% hladině se nicméně lze domnívat, že růst přidané hodnoty u nepodpořených firem byl o cca 10% vyšší, než u podpořených firem.

5.6.3 Změna přidané hodnoty na korunu osobních nákladů

Metoda nejbližšího souseda (*nearest neighbour* – NN).

Obrázek 20: Metoda nejbližšího souseda - průměrné hodnoty

```
ATT estimation with Nearest Neighbor Matching method
 (random draw version)
Analytical standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
258	168	0.156	0.181	0.861

```
Note: the numbers of treated and controls refer to actual
nearest neighbour matches
```

Caliper a radius matching.

Byl zvolen radius 0.01.

Obrázek 21: Caliper a radius matching - průměrné hodnoty

```
ATT estimation with the Radius Matching method
Analytical standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
218	337	0.115	0.120	0.958

```
Note: the numbers of treated and controls refer to actual
matches within radius
```

Stratifikace a intervalové párování (*interval matching*).

Obrázek 22: Stratifikace a intervalové párování - průměrné hodnoty

```
ATT estimation with the Stratification method
Analytical standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
257	485	0.084	0.098	0.858

Kernel matching a local linear matching (LLM).

Obrázek 23: Kernel matching a local linear matching - průměrné hodnoty

```
ATT estimation with the Kernel Matching method
Bootstrapped standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
258	484	0.097	0.109	0.893

Je zřejmé, že co se týče ukazatele přidané hodnoty na korunu osobních nákladů, neměla podpora žádný signifikantní dopad ve srovnání s nepodpořenými firmami.

5.6.4 Inovační aktivita

Při sledování dopadů podpory na inovační aktivitu firem, vyjádřenou patenty, bude nutné mírně pozměnit covariates – patbt (patenty v období před podporou) budou nahrazeny ukazatelem efektivity – phon. Metodicky je potom odhad shodný s předcházejícím. Nejprve tedy provedeme probabilistickou regresi, určíme skóre a posléze na párovaných subjektech odhadneme efekt podpory.

Obrázek 24: PSM odhad propensity score II

```
The treatment is treat

      treat |      Freq.     Percent        Cum.
------------+-----------------------------------
          0 |       489       65.46       65.46
          1 |       258       34.54      100.00
------------+-----------------------------------
      Total |       747      100.00


Estimation of the propensity score

Iteration 0:   log likelihood = -481.47186
Iteration 1:   log likelihood = -456.20747
Iteration 2:   log likelihood = -455.69884
Iteration 3:   log likelihood =  -455.6917
Iteration 4:   log likelihood =  -455.6917

Probit regression                                 Number of obs   =        747
                                                  LR chi2(9)      =      51.56
                                                  Prob > chi2     =     0.0000
Log likelihood =  -455.6917                       Pseudo R2       =     0.0535

------------------------------------------------------------------------------
       treat |      Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
         age |  -.0012801   .0009351    -1.37   0.171    -.0031129    .0005526
      sizemc |  -.0346336   .2007807    -0.17   0.863    -.4281566    .3588893
      sizesm |   .0098431   .1280917     0.08   0.939     -.241212    .2608982
      sizelg |   .0824801    .161725     0.51   0.610    -.2344951    .3994553
     lnTAS46 |   .0585177   .0290362     2.02   0.044     .0016077    .1154276
        indc |   .4858888   .1259852     3.86   0.000     .2389624    .7328151
        indj |   .3862778   .1851837     2.09   0.037     .0233245    .7492312
        indm |   .8832959   .1595271     5.54   0.000     .5706286    1.195963
      phon46 |   -.109119   .0430476    -2.53   0.011    -.1934908   -.0247473
       _cons |  -1.024561   .3164793    -3.24   0.001    -1.644849   -.4042732
------------------------------------------------------------------------------
```

Ve srovnání s probabilistickým odhadem s původními covariates lze konstatovat jediný podstatný rozdíl, a sice že na podporu dosáhly s vyšší pravděpodobností firmy s nižším podílem přidané hodnoty na nákladech, tedy de facto méně konkurenceschopné firmy. Algoritmus identifikoval 7 bloků, podmínky rovnováhy byly splněny – viz následující tabulka.

Obrázek 25: Common support a test rovnováhy

```
Note: the common support option has been selected
The region of common support is [.10325057, .62268274]


Description of the estimated propensity score
in region of common support

                  Estimated propensity score
-------------------------------------------------------------
      Percentiles      Smallest
 1%     .1219179       .1032506
 5%     .1594934       .1035887
10%     .1864161       .1079348       Obs                 731
25%      .264235       .1185652       Sum of Wgt.         731

50%     .3650624                      Mean           .3511845
                        Largest       Std. Dev.      .1143931
75%     .4293775       .5862731
90%     .5047435       .5886666       Variance       .0130858
95%     .5332124       .5979142       Skewness      -.0985219
99%     .5843976       .6226827       Kurtosis       2.243364


*******************************************************
Step 1: Identification of the optimal number of blocks
Use option detail if you want more detailed output
*******************************************************


The final number of blocks is 7

This number of blocks ensures that the mean propensity score
is not different for treated and controls in each blocks


*********************************************************
Step 2: Test of balancing property of the propensity score
Use option detail if you want more detailed output
*********************************************************


The balancing property is satisfied


This table shows the inferior bound, the number of treated
and the number of controls for each block
```

Inferior of block of pscore	treat 0	1	Total
.1032506	71	19	90
.2	262	115	377
.4	109	77	186
.5	21	11	32
.525	4	17	21
.55	6	18	24
.6	0	1	1
Total	473	258	731

```
Note: the common support option has been selected
```

Párování a odhady efektů podpory – inovační aktivita

Podobně jako v předchozím případě budeme kombinovat difference in difference a PSM, tedy budeme sledovat rozdíl mezi výstupní proměnnou – patenty mezi oběma skupinami na základě párování. Párování provedeme stejně jako v předcházejícím případě několika standardními metodami.

5.6.5 Změna patentů (inovační aktivita)

Metoda nejbližšího souseda (*nearest neighbour* – NN).

Obrázek 26: NN

```
ATT estimation with Nearest Neighbor Matching method
(random draw version)
Analytical standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
258	167	0.109	0.024	4.431

```
Note: the numbers of treated and controls refer to actual
nearest neighbour matches
```

Caliper a radius matching.

Byl zvolen radius 0.01.

Obrázek 27: radius matching

```
ATT estimation with the Radius Matching method
Analytical standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
255	473	0.090	0.023	3.914

```
Note: the numbers of treated and controls refer to actual
matches within radius
```

Stratifikace a intervalové párování (*interval matching*).

Obrázek 28: Stratifikace

```
ATT estimation with the Stratification method
Analytical standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
257	474	0.087	0.025	3.412

Kernel matching a local linear matching (LLM).

Obrázek 29: Kernel matching

```
ATT estimation with the Kernel Matching method
Bootstrapped standard errors
```

n. treat.	n. contr.	ATT	Std. Err.	t
258	473	0.091	0.024	3.759

Na základě všech použitých metod se lze domnívat, že podpora VaV měla u podpořených firem ve vztahu k nepodpořeným skutečně pozitivní, statisticky významný efekt. Lze konstatovat, že podpora zvýšila inovační aktivitu a to zhruba tak, že na deset firem připadá v podpořeném vzorku jedna, která svou inovační aktivitu zvýšila oproti kontrolní skupině (tedy o 1 patent více). Jinými slovy u 100 podpořených firem najdeme o 10 více firem, které přihlásily ve sledovaném období alespoň jeden patent ve srovnání s kontrolní skupinou[9].

[9] Přestože z hlediska dat může jít i o více patentů, maximum patentů ve vzorku bylo v obou obdobích 2, medián patentů (u firem, které patenty přihlašovaly) byl 1, průměr 1,16. S určitou mírou zjednodušení tedy lze konstatovat, že u 100 podpořených firem bylo získáno o 10 více patentů, než u 100 firem nepodpořených.

5.7 Double difference (Difference in difference)

Jednoduchá aplikace double difference byla představena už u náhodného výběru, a to včetně přesnějších odhadů s kontrolními proměnnými (odhady rovnice 9 byly ukázány u tabulek 8-11). V této podkapitole představíme poslední z možných přístupů, kdy budeme odhadovat rovnici (7), resp. při zahrnutí fixních efektů rovnici (8). Přístup k odhadu je založen v podstatě na panelových datech, kdy u dané firmy opět sledujeme dvě období – před a po podpoře. Odhad (7) ukazuje následující tabulka

Obrázek 30: Výsledky DD

Source	SS	df	MS
Model	3.81036019	3	1.27012006
Residual	62.909854	1490	.042221379
Total	66.7202142	1493	.04468869

Number of obs =	1494
F(3, 1490) =	30.08
Prob > F =	0.0000
R-squared =	0.0571
Adj R-squared =	0.0552
Root MSE =	.20548

pat	Coef.	Std. Err.	t	P>|t|	[95% Conf.	Interval]
treat	.0246588	.0158111	1.56	0.119	-.0063556	.0556732
t	.0224949	.013141	1.71	0.087	-.0032818	.0482716
tT	.0976602	.0223603	4.37	0.000	.0537992	.1415211
_cons	.0102249	.0092921	1.10	0.271	-.008002	.0284518

Pro odhad s fixními efekty (8) potom získáme následující výstup (proměnná treat vypadne kvůli kolinearitě, což je standardní (viz Shahidur 2010).

Obrázek 31: DD

```
Fixed-effects (within) regression               Number of obs      =      1494
Group variable: idn                             Number of groups   =       747

R-sq:  within  = 0.0828                         Obs per group: min =         2
       between = 0.0427                                        avg =       2.0
       overall = 0.0549                                        max =         2

                                                F(2,745)           =     33.61
corr(u_i, Xb)  = 0.0380                         Prob > F           =    0.0000

------------------------------------------------------------------------------
         pat |      Coef.   Std. Err.      t    P>|t|     [95% Conf. Interval]
-------------+----------------------------------------------------------------
       treat |          0  (omitted)
           t |   .0224949   .0109934     2.05   0.041     .0009132    .0440766
          tT |   .0976602    .018706     5.22   0.000     .0609374    .1343829
       _cons |   .0187416   .0062894     2.98   0.003     .0063946    .0310887
-------------+----------------------------------------------------------------
     sigma_u |   .1659754
     sigma_e |  .17189772
         rho |  .48247717   (fraction of variance due to u_i)
------------------------------------------------------------------------------
F test that all u_i=0:     F(746, 745) =     1.86            Prob > F = 0.0000
```

Je zjevné, že i tato metoda přináší velmi podobné výsledky – podpora VaV zvýšila inovační aktivitu podpořených firem ve srovnání s kontrolní skupinou pravděpodobně o 10%, resp. na 10 podpořených firem připadá o jeden patent více, než na 10 nepodpořených firem.

5.8 Shrnutí praktické ukázky využití metodiky

Praktická část této metodiky je stran vyvozených závěrů pouze orientační, což je dáno strukturou dat (neúspěšní žadatelé jsou vybráni z programu beta, zatímco úspěšní jsou z projektů vedených v databázi ISVAV – existuje tedy časový i programový nesoulad mezi oběma skupinami, přesto jsou skupiny ve sledovaných znacích relativně homogenní). V ukázce byly provedeny všechny kroky CIE, kdy byly blíže diskutovány i jednotlivé metody (náhodný výběr, PSM, DD, instrumentální proměnné, RDD), tak aby byl postup reprodukovatelný uživateli v TAČR. Jak uvádíme výše, pro účely TAČR je pravděpodobně nejvhodnější metodou kombinace PSM a DD. Aplikace ukázala, že podpořené subjekty vykazovaly vyšší inovační aktivitu (více patentů), než subjekty nepodpořené – v tomto ohledu lze hodnotit vynaložení veřejných prostředků na VaV aktivity jako úspěšné. Ve finančních indikátorech se nicméně tento dopad alespoň ve sledovaném období neodrazil. Opět zde narážíme na to, že je třeba jasně definovat cíl programu a k tomu přiřadit relevantní výstupní indikátory. Jinými slovy pokud bylo cílem podpory zvýšit inovační aktivitu, pak byla podpora úspěšná (nehodnotíme zde efektivitu). Pokud bylo cílem zvýšení konkurenceschopnosti, pak úspěch nelze, alespoň v krátkém období, které jsme sledovali, potvrdit.

Literatura

Bryson, A. Dorsett, R., Purdon, S. (2002). The Use of Propensity Score Matching in the Evaluation of Active Labour Market Policies. Working Paper 4, Department for Work and Pensions, London.

Caliendo, M., Kopeinig, S. (2008). Some Practical Guidance for the Implementation of Propensity Score Matching." Journal of Economic Surveys 22 (1): 31–72.

Correa, P., Andros, L., Borja-Vega, Ch. (2013): The Impact of Government Support on Firm VaV Investments – A Meta Analysis. Policy Research Working Paper 6532. World Bank, Entrepreneurship and Innovation unit.

Heckman, J.J., Ichimura, H., Todd P. (1997): Matching as an Econometric Evaluation Estimator: Evidence from Evaluating a Job Training Programme. Review of Economic Studies 64 (4): 605–54

Imbens, G. (2004): Nonparametric Estimation of Average Treatment Effects Under Exogeneity. Review of Economics and Statistics, vol. 86(1): 4-29

Khandker S., Koolwal G., Samad H. (2010): Handbook on Impact Evaluation, Quantitative Methods and Practicies. The World Bank 2010.

Kleiknecht A., Montfort, K., Brouwer E. (2002): The Non-Trivial Choice between Innovation Indicators. Economics of Innovation and New Technology 11(2): 109-121

Lechner, M (1999): Earnings and Employment Effects of Continuous Off-the-Job Training in East Germany after Unification. Journal of Business Economic Statistics 17 (1): 74–90.

Miguel, E., Kremer M. (2004): Worms: Identifying Impacts on Education and Health in the Presence of Treatment Externalities. Econometrica 72 (1): 159–217.

Mirošník, K., Petkovová, L., Čadil, J. (2014): Statistical Analysis of Cohesion Funding in the Czech Republic. In: NERUDOVÁ, Danuše, ROZMAHEL, Petr (ed.). 17th International Conference Enterprise and Competitive Environment 2014. Brno, 06.03.2014 – 07.03.2014. Amsterdam : Elsevier, 2014, pp. 437–444. Procedia Economics and Finance 12. ISSN 2212-5671.

OECD (2012): OECD Science, Technology and Industry Outlook 2012

Potluka O., Špaček M. (2013): Postupy a metody kontrafaktuálních dopadových evaluací pro Operační program Zaměstnanost v období 2014 – 2020.

Ravallion, M. (2008): Evaluating Anti-Poverty Programs. In Handbook of Development Economics, Vol. 4, ed. T. Paul Schultz and John Strauss, Amsterdam: North-Holland.

Rosenbaum, P.R., Rubin, D.B. (1983): The central role of the propensity score in observational studies for causal effects. Biometrika, 70: 41–55

Roy, A.D. (1951): Some Thoughts on the Distribution of Earnings. Oxford Economic Papers 3(2): 135–46.

Rubin, D. (1974): Estimating Causal Effects of Treatments in Randomized and Nonrandomized Studies, Journal of Educational Psychology, 66 (5): 688–701

Shahidur R. Khandker, Gayatri B. Koolwal, Hussain A. Samad (2010): Handbook on Impact Evaluation: Quantitative Methods and Practices, World Bank Publications 2010, pp 239.

Smith, J., Todd, P. (2005): Does Matching Overcome LaLonde'sCritique of Nonexperimental Estimators?, Journal of Econometrics 125 (1–2): 305–53.

Publikace autorů předcházející metodice

Petkovová, L., Čadil, J., Mirošník, K., Rehák, J. (2015): Statistical Analysis of R&D Funding in the Czech Republic. In: HROMADA, Eduard (ed.). IISES 3rd and 4th Economics and Finance Conference. Řím, 14.04.2015 – 17.04.2015. Oxford : Elsevier B.V, 2015, s. 664–670. Procedia Economics and Finance 30. ISSN 2212-5671

Mirošník, K. (2015): Analýza dopadu R&D dotací na soukromé firmy v České republice v 2007-2010. Socioekonomické a humanitní studie. 2015, roč. 5, č. 1, s. 5–10. ISSN 1804-6797.

Čadil, J., Petkovová, L. (2014): Human Capital, R&D and growth – some empirical findings. In: *The 8th International Days of Statistics and Economics*. Praha, 11.09.2014 – 13.09.2014. Slaný : Melandrium, 2014, s. 308–315. ISBN 978-80-87990-02-5

Mirošník, K., Petkovová, L., Čadil, J. (2014): Statistical Analysis of Cohesion Funding in the Czech Republic. In: NERUDOVÁ, Danuše, ROZMAHEL, Petr (ed.). *17th International Conference Enterprise and Competitive Environment 2014* [online]. Brno, 06.03.2014 – 07.03.2014. Amsterdam : Elsevier, 2014, s. 437–444. Procedia Economics and Finance 12. ISSN 2212-5671.

Čadil, J., Petkovová, L., Blatná, D. (2014): Human Capital, Economic Structure and Growth. In: NERUDOVÁ, Danuše, ROZMAHEL, Petr (ed.). *17th International Conference Enterprise and Competitive Environment 2014* [online]. Brno, 06.03.2014 – 07.03.2014. Amsterdam : Elsevier, 2014, s. 85–92. Procedia Economics and Finance 12. ISSN 2212-5671.