

Vysoká škola ekonomická v Praze

Fakulta informatiky a statistiky

Katedra informačního a znalostního inženýrství

Reaktivní multiagentní modely v ekonomii

DOKTORSKÁ DISERTAČNÍ PRÁCE

Doktorand	:	ing. Jan Burian
Školitel	:	doc. PhDr. Karel Pstružina CSc.
Obor	:	Informatika

© 2010 Jan Burian

burianj@vse.cz

Při citaci uvádějte odkaz:

Burian J. Reaktivní multiagentní modely v ekonomii, disertační práce. VŠE-FIS, Praha, 2010.

Praha, květen, 2010

Prohlášení

Prohlašuji, že doktorskou práci na téma „Reaktivní multiagentní modely v ekonomii“ jsem vypracoval samostatně. Použitou literaturu a podkladové materiály uvádím v příložených seznamech literatury.

V Praze dne 1. května 2010

.....

Podpis

Abstrakt a klíčová slova

Multiagentní modely jsou softwarové modely reálných systémů, které jsou složené z velkého množství aktivních autonomních prvků, tzv. agentů. Tématem této práce jsou aplikace multiagentních modelů v ekonomii. V první části této práce jsem na základě syntézy mnoha zdrojů vytvořil návrh metodologie multiagentních modelů sociálních systémů. Tuto metodologii jsem ilustroval rozбором již existujícího a dobře známého modelu etnocentrického chování. Podrobně jsem se věnoval zejména komplexitě a samoorganizaci a prakticky aplikoval a sledoval vývoj různých typů strukturální complexity. Dále jsem se pokusil vysvětlit hlavní odlišnosti mezi multiagentními modely a analytickými modely, které jsou využívány v ekonomii hlavního proudu.

Druhá část ukazuje praktické aplikace tří multiagentních modelů v ekonomii. Všechny zde popsané modely mají výzkumný charakter - cílem bylo získat vhled do fundamentálních zákonitostí dynamiky systému. Výzkumné modely je výhodné dělat co nejjednodušší, abychom dokázali zjistit, jak systém vytváří výsledné chování. Všechny modely ukazují alternativní přístup k modelování některých typických ekonomických situací. Alternativa spočívá zejména v opuštění předpokladů racionality agentů. Soustředil jsem se na modely s reaktivními agenty. Reaktivní agenti, které nedisponují pamětí (nebo jen nepřímou jako je například výše úspor) a nejsou schopny bohatší symbolické reprezentace prostředí. Reaktivita agentů nemusí znamenat nechtěné omezení. Pokud je vhodně použita, může představovat určitý typ omezené racionality.

Model transakčních nákladů na finančním trhu jsem založil na již hotovém modelu, který ukazoval, jakým způsobem vzniká díky omezené racionalitě agentů nestabilita na finančních trzích. Nestabilita na finančních trzích je v rozporu s tzv. Hypotézou efektivního trhu. Původní model jsem modifikoval, doplnil o působení transakčních nákladů a zkoumal, jak nestabilitu a neefektivitu trhu ovlivňuje výše transakčních nákladů. Zjistil jsem, že transakční náklady vedou ke snižování nestability trhu, snižování objemu obchodu a do jisté míry mohou zvyšovat efektivitu modelovaného trhu.

Model evoluce averze k riziku a nejistotě je inspirován psychologickými a neurologickými důkazy, které zpochybňují tzv. Hypotézu očekávaných užitek. Model ukazuje, že existuje velmi jednoduchý evoluční mechanismus, který povede ke vzniku averze k riziku a nejistotě. Tato averze se vyvinula díky situacím, kdy se agent může opakovaně rozhodovat a získávat odměnu a zároveň existuje šance, že díky některým, z krátkodobého hlediska výhodným, volbám ztratí možnost pokračovat v získávání odměny. Model naznačuje, že sexuální reprodukce vznik této averze podporuje. Pokud se tato averze vyvinula i u lidí, může ovlivňovat i jednorázové rozhodování a vést k chování, které je „neracionální“, resp. v rozporu s Hypotézou očekávaného užitku.

Model monopsonu na trhu práce zkoumá situaci, kdy zaměstnavatel může díky své síle snižovat mzdy až k existenčnímu minimu. Pracovníci jsou v takovém případě „paradoxně“ nuceni zvyšovat nabídku práce při snižujících se mzdách. Model dále zkoumá vliv spotřebních půjček na zisky zaměstnavatele, výši mezd, nezaměstnanost a blahobyt. Model ukazuje, že zvyšování pravděpodobnosti, že si pracovníci vezmou spotřební půjčku, zvyšuje zisky zaměstnavatelů, zvyšuje nezaměstnanost, snižuje blahobyt a v některých situacích umožňuje zaměstnavatelům snížit mzdy až k existenčnímu minimu pracovníků. Model také napovídá, že pro velmi nízké úrovně mezd povede snížení minimálních mezd „paradoxně“ ke zvýšení nezaměstnanosti. V závěru vyvozují doporučení jak pro zaměstnavatele snažící se maximalizovat zisk, tak pro zaměstnance bránící se snižování mezd.

Klíčová slova: multiagentní modely, multiagentní modely v ekonomii, reaktivní agenti, finanční trhy, hypotéza očekávaných užitek, monopson

Abstract and keywords

Multi-agent models are software models of real systems, which are compounded of a large amount of active autonomous units – agents. The main theme of this study is the application of multi-agent models in economics. In the first part of this study I synthesized information from many sources and created a proposal of methodology of multi-agent modeling in social sciences. This methodology is illustrated by a detailed analysis of a well-known model of ethnocentric behavior. I focused on the issue of complexity a self-organization a observed the development of different kinds of structural complexity. Another important issue I'm dealing with is the relation between multi-agent models and analytical models used by the mainstream economy

The second part contains three applications of multi-agent models in economy. All described models are research models – the aim is to get insight into the fundamental laws controlling the dynamics of the system. Research models should be as simple as possible – than we can understand how the behavior of the system is resulting from the interaction of agents. All models represent an alternative to some typical economic situation. The alternative consists mainly in abandoning of the assumption of full rationality of agents. I focused on models with reactive agents, which don't dispose any memory (or only an indirect form of memory) and have no ability of complex symbolical representation of the environment. Reactivity of agents doesn't necessarily mean an unwanted limitation. It could be properly used to model different kinds of bounded rationality.

The model of transaction costs on financial markets is based on another model, which showed how the instability of the financial market could result from interactions of agents with bounded rationality. The instability of the financial markets contradicts the Effective Markets Hypothesis. I modified and extended this model with the mechanism of transaction cost. The model shows that higher transaction costs lead to greater stability of the market, they decrease the volume of trade and to some extent they can increase the efficiency of the modeled market.

The model of evolution of aversion to risk and ambiguity is inspired by psychological and neurological experiments whose results contradict the Expected Utility Hypothesis. Model shows that there exists very simple mechanism which leads to evolution of risk and ambiguity aversion. This aversion evolves because of situations when the agent can repeatedly decide between two choices, one brings him low but risk free utility, second brings him higher utility which involves the risk that the agent will lose its ability to get any utility in the future (e.g. it will die). The model shows that sexual reproduction strengthens this mechanism. If this mechanism has also evolved in humans, it can influence their behavior and lead to „irrational” behavior contradicting the Expected utility hypothesis.

The model of monopsony on the labor market analyses the situation in which the employer could cut the wages to the existential minimum of workers. In such a case are the workers paradoxically to increase the labor supply when the wages are decreasing. The model further analyses the influence of consumer loans on the profit of the employer, unemployment and welfare. The model shows that the increasing of the probability of consumer loans increases the profits, increases unemployment, decreases well-fare and in some situations it enables the employer to decrease the wages to the existential minimum. The model also suggests that for very low wages the decrease of minimum wage could lead to increase of unemployment. From the results recommendations could be obtained both for the profit maximizing employer and for the workers resisting the wage cuts.

Keywords: multi-agent models, agent-based computational economy, reactive agents, financial markets, Expected Utility Hypothesis, monopsony

Obsah

1. ÚVOD	6
1.1. VYMEZENÍ TÉMATU PRÁCE	6
1.2. STAV ZKOUMANÉ PROBLEMATIKY VE SVĚTĚ A V ČR	7
1.3. CÍLE PRÁCE, METODY A STRUKTURA ŘEŠENÍ.....	7
1.4. POUŽITÁ TERMINOLOGIE	9
1.4.1. Modelování.....	9
1.4.2. Ekonomie	10

Část I: Metodologie multiagentních modelů

2. METODOLOGIE	12
2.1. ÚVOD.....	12
2.2. CELULÁRNÍ AUTOMATY	13
2.3. DYNAMIKA MULTIAGENTNÍCH MODELŮ.....	15
2.4. ZÁSADY MULTIAGENTNÍHO MODELOVÁNÍ	17
2.4.1. Tvorba modelu.....	17
2.4.2. Typy agentů	18
2.4.3. Interpretace chování modelu.....	19
2.5. LOGIKA A CÍLE MODELU.....	20
2.5.1. Dedukce.....	20
2.5.2. Indukce	21
2.5.3. Abdukce.....	25
2.6. KOMPLEXITA, SAMOORGANIZACE A KOGNICE.....	26
2.7. NÁSTROJE	28
2.7.1. Vlastnosti nástrojů pro tvorbu multiagentních modelů	28
2.7.2. NetLogo	28
3. MULTIAGENTNÍ A ANALYTICKÉ MODELÝ V EKONOMII	31
4. METODOLOGICKÝ ROZBOR MODELU EVOLUCE ETNOCENTRICITY.....	34
4.1. ETNOCENTRICITA.....	34
4.2. POPIS MODELU	35
4.3. VÝSLEDKY	36
4.4. ANALÝZA MODELU	36
4.4.1. Cíle, základní charakteristiky a logika modelu	36
4.4.2. Interpretace modelu	37
4.4.3. Vztah k analytickým modelům	37
4.4.4. Nástroje	38
4.4.5. Komplexita a samoorganizace	38

Část II : Aplikace multiagentních modelů

5. MODEL TRANSAKČNÍCH NÁKLADŮ NA FINANČNÍCH TRZÍCH	42
5.1. ÚVOD.....	42
5.1.1. Stabilita finančních trhů.....	42
5.1.2. Chování trhů a multiagentní modely.....	43
5.2. POPIS MODELU	43
5.2.1. Původní model a jeho modifikace.....	43
5.2.2. Model s transakčními náklady.....	46
5.3. VÝSLEDKY EXPERIMENTŮ	47
5.4. ZÁVĚR.....	51

6. MODEL EVOLUCE AVERZE K RIZIKU A NEJISTOTĚ	52
6.1. ÚVOD.....	52
6.1.1. Hypotéza očekávaného užitku a averze k riziku a nejistotě	52
6.1.2. Neuronální koreláty averze k riziku a nejistotě	55
6.2. POPIS MODELU	56
6.2.1. Averze k riziku a nejistotě.....	56
6.2.2. Opakovaná rozhodnutí, fitness a délka života agentů	56
6.2.3. Typy chování	57
6.2.4. Populace agentů.....	57
6.2.5. Fitness a pravděpodobnost reprodukce.....	57
6.2.6. Reprodukce.....	58
6.2.7. Životní cyklus agentů.....	58
6.2.8. Formální popis modelu	58
6.3. VÝSLEDKY EXPERIMENTŮ	58
6.3.1. Diskuse k modelu.....	59
6.3.2. Algebraicko - numerické řešení.....	59
6.4. ZÁVĚR.....	60
7. MODEL MONOPSONU NA TRHU PRÁCE	64
7.1. ÚVOD.....	64
7.2. POPIS MODELU	65
7.2.1. Hlavní prvky modelu	65
7.2.2. Pracovníci	65
7.2.2.1. Individuální nabídka práce	65
7.2.2.2. Existenční a statusové minimum	65
7.2.2.3. Půjčky a dluhy, utrácení a spoření.....	66
7.2.3. Zaměstnavatelé.....	67
7.2.3.1. Mzdy a zisk	67
7.2.3.2. Výběr pracovníků	69
7.2.3.3. Interakce mezi pracovníky probíhá nepřímo přes zaměstnavatele.....	70
7.2.4. Možná rozšíření modelu	70
7.2.5. Formální popis modelu	70
7.3. NASTAVENÍ MODELU	71
7.4. VÝSLEDKY EXPERIMENTŮ	72
7.4.1. Situace s fixní mzdou	72
7.4.2. Situace s pohyblivou mzdou	74
7.5. ZÁVĚR.....	79
8. ZÁVĚR	80
8.1. DOSAŽENÉ VÝSLEDKY	80
8.2. BUDOUCNOST MULTIAGENTNÍCH MODELŮ	81
9. LITERATURA.....	83
10. PŘÍLOHA – POPIS PŘILOŽENÉHO DVD	90

1. Úvod

1.1. Vymezení tématu práce

Původní téma mého doktorandského výzkumu bylo „Aplikace kognitivních věd v umělé inteligenci“. Kognitivní věda zkoumá poznávací procesy u přirozených organismů a jejich societ i umělých systémů. Mezi poznávací procesy řadíme vnímání, učení a usuzování, ale v širším kontextu i komunikaci, paměť, rozhodování, vědomí, kreativitu apod. V průběhu svého doktorského studia jsem se setkal s řadou osobností působících v oblasti umělé inteligence, kognitivních věd a umělého života zejména na konferenci Kognice a umělý život. Zabýval jsem se filosofickými a metodologickými aspekty kognitivních věd (Burian, 2004, 2005a, 2005b, 2006b, 2008a) a neurovědami (Burian, 2006c, 2009b). Postupně jsem se zaměřil na modely poznávacích procesů, které nejsou založeny na přímé symbolické reprezentaci světa, ale popisují kognitivní proces jako komplexní interakce mezi velmi jednoduchými prvky (Burian, 2006a). Jedním typem takových modelů jsou multiagentní modely (Agent-Based Models, ABM). Jedná se o softwarové modely reálných systémů, které jsou složeny z velkého množství aktivních autonomních prvků, tzv. agentů. Mezi agenty a jejich prostředím a mezi agenty navzájem dochází k interakcím, které mohou být jak strukturálně, tak funkčně komplexní. Interakce jsou uskutečňovány iterativním výpočtem, krok za krokem. Agenty mohou být různorodé – mohou mít odlišné nejen hodnoty parametrů, ale i funkce, které určují jejich chování. Multiagentní modely jsou užívány ve fyzice (např. modelování tekutin), biologii (modelování ekosystémů) nebo v sociálních vědách (např. modely šíření názorů mezi lidmi) a v ekonomii (např. modelování trhů). Tématem této práce jsou aplikace multiagentních modelů v ekonomii.

Pro multiagentní modely v ekonomii se vžila zkratka ACE (Agent-based computational economy). ACE dnes představuje rozvíjející se alternativu nebo doplněk k běžným ekonomickým modelům, které jsou založeny na ekonometrii nebo metodách operačního výzkumu.

Podle (Axelrod a Tesfatsion, 2005) může rozvoj ACE přispět k:

1. Porozumění empiricky získaným datům o chodu ekonomiky. (Proč ekonomika funguje zrovna tímto způsobem.)
2. Porozumění kvalitativním vlastnostem ekonomických systémů. (Jaké chování můžeme očekávat pro různé parametry.)
3. Porozumění normativnímu. (Jaká opatření mohou vést k žádoucím společenským výsledkům.)
4. Rozvoji nových výpočetních metod a nástrojů pro systematické výpočetní experimenty.

Modely popsané v druhé části této práce jsou přínosné zejména z hlediska prvních dvou bodů. Z modelu transakčních nákladů na finančních trzích a modelu monopsonu na trhu práce plynou i normativní závěry. Z hlediska logického usuzování je v modelech kladen důraz zejména na induktivní

nalezení obecných pravidel, které vedou k empiricky pozorovanému chování, a na abduktivní zkoumání chování modelu pro velké množství kombinací různých hodnot parametrů modelu.

1.2. Stav zkoumané problematiky ve světě a v ČR

První multiagentní modely se objevily v 70. letech, některé z nich nebyly ani implementovány softwarově. Např. Thomas Schelling pro svůj model rasové segregace (viz kapitola 2.5.3.) použil jako prostředí šachovnici a agenty představovaly mince. Rozkvět multiagentních modelů nastal až na přelomu 80. a 90. let a souvisel s růstem výkonu výpočetní techniky. Multiagentní modely, které obsahují velké množství agentů, jejichž dynamiku sledujeme po dlouhou dobu, jsou na výpočetní výkon velmi náročné¹.

V posledních deseti letech vznikala snadno ovladatelná vývojová prostředí pro tvorbu multiagentních modelů, jako např. systém NetLogo, který využívám v této práci. Díky tomu se multiagentní modely stávají pomůckou nejen vědců, ale začínají se používat i ve výuce.

Již výše zmíněný Schellingův model segregace je příkladem aplikace multiagentních modelů na rozhraní sociologie a ekonomie. Čistě ekonomické aplikace se začaly rozvíjet na konci 80. let např. v SantaFe Institute pro výzkum komplexity, kde mimo jiné začali vytvářet i multiagentní model finančního trhu, kde agenti mohli vytvářet různé investiční strategie, které spolu soutěžily a v důsledku této soutěže začal trh projevovat nestabilitu známou z reálných trhů (pro přehled vývoje tohoto modelu viz LeBaron, 2002). V posledních letech došlo k velkému nárůstu množství publikací o multiagentních modelech v ekonomii. V nedávno vydané Encyclopedy of Complexity (Meyers, R, 2009) zabírá heslo „Agent Based Models in Economics and Complexity“ 22 stránek. Rozsáhlý přehled literatury a možných aplikací podávají internetové stránky Leigh Tesfatsion (2010).

V době, kdy jsem se začal o multiagentní modely zajímat, tedy kolem roku 2003, existoval v Čechách a na Slovensku pouze malý počet lidí, kteří se touto problematikou zabývali (a většinu z nich propojovala výše zmíněná konference Kognice a umělý život), viz např. (Pospíchal, 2002; Zajac, 2004; Pospíchal a Kvasnička, 2005; Pospíchal a Kvasnička, 2006). V současné době se však, v důsledku prudkého nárůstu zájmu o multiagentní modely v zahraničí, začíná o tuto problematiku zajímat řada odborníků i mimo oblast umělého života a kognitivních věd. Jsou to ekonomové a sociologové (viz např. Cahlík, 2006; Kvasnička, 2009), ale i technici, kteří používají multiagentní modely jako optimalizační algoritmy (Macaš, Lhotská, 2009).

1.3. Cíle práce, metody a struktura řešení

Prvním cílem, kterému se věnuji v první části této práce, bylo vytvořit ucelenou metodologii tvorby multiagentních modelů (která dosud minimálně v češtině chybí). Zaměřuji se zejména na problematiku formálního popisu modelů, na návrh, tvorbu a interpretaci modelů, na využití různých typů logického usuzování v modelech, na problematiku komplexity a samoorganizace a konečně i na popis vývojových prostředí pro tvorbu modelů. Tuto metodologii ilustruji řadou konkrétních modelů, které jsem však nevytvářel já. Některé z těchto modelů jsem ale modifikoval nebo doplnil. Z metodologického hlediska jsem pak podrobně rozebral již existující model evoluce etnocentického chování (Hammond a Axelrod, 2003).

Tato část práce je založena na syntéze literatury, kterou jsem k tématu nastudoval. Většina tvrzení v této části je podložena citacemi. V této části se snažím využít i publikace, které jsem o

¹ Například model evoluce averze k riziku a nejistotě (kapitola 6) byl spouštěn celkem 12000 krát pro různé kombinace parametrů, obsahoval 250 agentů pokaždé běžel 3000 kroků, a výpočty trvaly na průměrném notebooku (Centrino Duo, 2GBRam) asi 20 hodin.

metodologii multiagentních modelů vytvořil (Burian, 2009a)² a zkušenosti z výuky kurzu Komplexní systémy, který učím na VŠE v Praze.

Tvrzení, která citacemi nepodkládám, jsou výsledkem syntézy vlastních zkušeností s tvorbou a výukou multiagentního modelování a studia velkého množství různých zdrojů. Popřípadě se jedná o mnou vytvořená data (např. struktury na obrázku 5. v kapitole 2.4.3.) nebo mnou modifikované ilustrační modely. Originální příspěvky lze nalézt v kapitole o komplexitě a samoorganizaci v multiagentních modelech. Originálním příspěvkem je také analýza strukturální komplexity v modelu etnocentricity.

Druhým cílem, kterému se věnuji ve druhé části této práce, bylo vytvořit několik aplikací multiagentních modelů v ekonomii, které budou podloženy transdisciplinárním výzkumem z oblasti společenských věd. Vytvořil jsem tři originální aplikace multiagentních modelů. Dva z těchto modelů, model transakčních nákladů na finančních trzích a model evoluce averze k riziku a neurčitosti, jsem už dříve prezentoval (Burian, 2007, 2008b). Oba modely jsem doplnil o nové, dosud neprezentované výsledky experimentů. Třetí model, model monopsonu na pracovním trhu, ještě jinde prezentován nebyl.

Na začátku každé kapitoly se snažím čtenáře seznámit s obecnějším kontextem, aby vyvstala motivace pro tvorbu modelů. Pokračuji popisem modelu, statistickou analýzou dat (používal jsem systém R s nadstavbou Rcommander (Fox, 2010)), interpretací výsledků a zobecňujícím závěrem. Číslování obrázků a grafů je relativní ke každé kapitole. Příslušná literatura je uvedena v závěru celé práce. Cituji podle normy APA užívané v psychologii a ve společenských vědách.

Společným rysem všech tří modelů je zpochybňování některých předpokladů ekonomie hlavního proudu, zejména předpokladu homogenních, plně racionálních agentů. Modely s omezenou racionalitou nám pomáhají zkoumat důsledky alternativního chápání ekonomického rozhodování. Omezenou racionalitou můžeme přitom označovat dvě poněkud odlišné skutečnosti. Na jedné straně můžeme jako omezenou racionalitu označit evolučně selektované rozhodovací mechanismy, které se ukázaly jako výhodné při často opakovaném rozhodování a nemusí tedy být racionální z hlediska jednorázového rozhodování. Příkladem takového rozhodovacího mechanismu je averze k riziku a nejistotě, o které pojednávám v příslušné kapitole v druhé části této práce. Na druhé straně můžeme tradičněji jako omezenou racionalitu chápat omezené schopnosti agentů získávat a interpretovat informace o ostatních agentech a o prostředí, kognitivní limity, jako je např. velikost paměti nebo schopnost provádět sofistikované optimalizace, a omezený čas, ve kterém se agenti musí rozhodovat (Gigerenzer, 2002).

Multiagentní modely mne vždy zajímaly spíše jako doplněk kognitivních věd. Model je pro mne nástroj, který mi umožní lépe pochopit, jakým způsobem může interakce extrémně zjednodušených aktivních prvků – agentů, generovat komplexní chování celého systému. Nesnažil jsem se tedy o tvorbu modelů, které by byly schopné přesně předpovídat chování reálných systémů a statisticky kalibrovat vytvořené modely na reálná data. Modely, které jsem vytvářel, byly vždy výzkumné - cílem bylo získat vhled do fundamentálních zákonitostí dynamiky systému. Výzkumné modely je výhodné dělat co nejjednodušší, abychom dokázali zjistit, jak systém vytváří výsledné chování.

Proto jsem se soustředil na modely s reaktivními agenty, které nedisponují pamětí (nebo jen nepřímou, jako je například výše úspor) a nejsou schopny bohatší symbolické reprezentace prostředí. Reaktivita agentů nemusí znamenat nechtěné omezení. Pokud je vhodně použita, může představovat nějaký typ omezené racionality. Přestože modely prezentované v této práci jsou relativně jednoduché, jejich verifikace, experimentování s nimi, statistické zpracování dat a vizualizace výsledků zabere stejné množství práce jako u modelů s deliberativními agenty.

² Článek jsem prezentoval už v roce 2007, vydání sborníku mělo dvouleté zpoždění. Díky aktivitě studentů se tento článek stal jádrem hesla o Multiagentním modelování na české Wikipedii. Tuto poznámku zde uvádím hlavně proto, abych se vyhnul podezření, že kopíruji informace z Wikipedie.

Případný kritik by však snadno mohl přílišnou jednoduchost těchto „toy-modelů“ napadnout. Modely jsou natolik jednoduché, že není smysluplné je přesně kalibrovat vůči empirickým datům (tj. hledat takové nastavení parametrů, které bude produkovat výsledky přesně souhlasící se skutečností). Na druhé straně, i když modely nejsou schopny dávat přesné predikce vývoje systému, ukazují, jaké jsou vzájemné závislosti mezi veličinami, které popisují vlastnosti systému jako celku. Další slabinou by snad mohlo být i statistické zpracování výstupních dat, které je spíše extenzivní – tj. ukazují řadu relativně jednoduchých souvislostí pro velké množství dat, než intenzivní – tj. nejsou aplikovány složitější statistické modely.

Moje práce je v češtině, protože část této práce původně vznikala se záměrem vytvořit studijní zdroje pro české studenty. Lze ji chápat i jako jistou protiváhu anglického tutoriálu³, který jsem vytvořil jako hlavní studijní zdroj pro výše zmíněný kurz Komplexní systémy. Tento kurz byl totiž původně plánován i pro zahraniční studenty.

Domnívám se, že práce má hodnotu i jako učebnice a sbírka podrobně rozebraných modelů⁴. Zajímavá může být také pro ekonomy, kteří hledají alternativu k současné ekonomii hlavního proudu. Konečně doufám, že je práce přínosná i jako ukázka snahy o transdisciplinární přístup k modelování. Ten spočívá ve vhodné kombinaci znalostí z oblasti modelování, kognitivní vědy a sociálních věd: ekonomie, behaviorální ekonomie a sociologie.

1.4. Použitá terminologie

1.4.1. Modelování

Agent. Aktivní autonomní a situovaný prvek, interagující s dalšími agenty a prostředím. Rozlišujeme reaktivní a deliberativní agenty.

Deliberativní agent. Může disponovat bohatou symbolickou reprezentací vnějšího prostředí a využívat metody tradiční umělé inteligence a strojového učení (včetně konekcionistických systémů, např. neuronových sítí apod.).

Multiagentní model (Agent-Based model, ABM). Softwarové modely reálných systémů, které jsou složeny z velkého množství aktivních autonomních prvků, tzv. agentů. Mezi agenty a jejich prostředím a mezi agenty navzájem dochází k interakcím, které mohou být jak strukturálně, tak funkčně komplexní. Interakce jsou uskutečňovány iterativním výpočtem, krok za krokem. Agenty mohou být různorodé – mohou mít odlišné nejen hodnoty parametrů, ale i funkce, které určují jejich chování.

Multiagentní modely v ekonomii (Agent-Based Computational Economy, ACE). Aplikace multiagentních modelů na problematiku trhů, omezených zdrojů, prodeje a nákupu, evoluce kooperativního a koordinovaného chování, vzniku koalic, šíření inovací apod..

Multiagentní systém (Multi-agent System, MAS). Dynamický systém složený z množství vzájemně interagujících aktivních a autonomních prvků, tzv. agentů.

NetLogo. Vývojové prostředí pro tvorbu multiagentních modelů. Disponuje speciálním programovacím jazykem, umožňuje jednoduché vytváření komunikačního rozhraní s uživatelem. Je distribuováno zdarma. V tomto prostředí byly vytvořeny modely popisované v této práci.

³ Complex Systems Tutorial. Dostupný na WWW: <eldar.cz/cognition/complex>.

⁴ Popis ovládání modelů je integrován přímo do modelů. Modely jsou na příloženém disku. Obsah disku je popsán v příloze.

Omezená racionalita. Omezené schopnosti agentů získávat a interpretovat informace o ostatních agentech a o prostředí, kognitivní limity, jako je např. velikost paměti nebo schopnost provádět sofistikované optimalizace, a omezený čas, ve kterém se agenty musí rozhodovat (Gigerenzer, 2002).

Reaktivní agent. Není u něj kladen důraz na symbolickou reprezentaci vnějšího světa a sofistikované rozhodování. Při vhodném využití může reprezentovat agenta s omezenou racionalitou.

1.4.2. Ekonomie

Hypotéza efektivních trhů (Effective Market Hypothesis, EMH). Na základě předpokladů o plné racionalitě agentů tato hypotéza tvrdí, že tržní cena reflektuje veškerou informaci o reálné hodnotě obchodovaných aktiv a neměla by se od ní odchýlovat.

Hypotéza očekávaného užitku (Expected Utility Hypothesis, EUH). Na základě předpokladů o plné racionalitě agentů tato hypotéza tvrdí, že agent je schopen přiřadit každé odměně nějaký subjektivní užitek a dokáže se rozhodnout pro takovou variantu, od které očekává, že mu v budoucnu přinese největší užitek. Očekávaný užitek nějakého rozhodnutí je dán sumou součinů pravděpodobností jednotlivých výsledků a užitků příslušných odměn.

Část I:

Metodologie multiagentních modelů

2. Metodologie

2.1. Úvod

První část této práce, je úvodem do problematiky multiagentních modelů sociálních systémů. Nejprve se zmíním o rozdílu mezi multiagentními systémy a multiagentními modely. Poté se budu soustředit na hlavní cíl této části - vytvořit ucelenou metodologii tvorby multiagentních modelů. Poté se podrobněji zaměřím na rozdíl mezi multiagentními a analytickými modely v ekonomii. Nakonec podrobně z metodologického hlediska rozeberu ukázkový příklad multiagentního modelu - model evoluce etnocentrického chování.

Multiagentní systém (Multi-Agent System, MAS) je dynamický systém složený z množství vzájemně interagujících aktivních a autonomních prvků, tzv. agentů. Autonomie agenta znamená, že agent není centrálně řízen. Míra autonomie se může lišit a závisí na prostředí, ve kterém je agent realizován. Globální vlastnosti a chování multiagentního systému jako celku jsou důsledkem interakcí mezi agenty a prostředím, ve kterém jsou situovány (někdy je prostředí chápáno jako zvláštní typ agenta). Termín agent je velmi široký. Může označovat organismus, společenství nebo umělý systém (např. robot), který existuje v reálném světě. V kontextu multiagentních systémů však termín agent často označuje i nějakou relativně autonomní softwarovou aplikaci. Jde například o mobilní aplikace schopné se kopírovat a spouštět své instance v prostředí počítačové sítě. Nebo může jít o vzájemně komunikující softwarové komponenty řídící relativně samostatné složky dopravních, průmyslových či informačních procesů. Komunita která se zabývá těmito typy agentů se skládá zejména ze softwarových inženýrů, kteří se zabývají architekturou informačních systémů, a z odborníků na sémantiku a komunikační protokoly, které zajišťují efektivní přenos informací a znalostí i mezi heterogenními agenty.

Specifickým typem multiagentních systémů jsou multiagentní modely (Agent-based model, ABM). Zde jsou agenty softwarové modely reálných agentů v softwarově simulovaném prostředí. Komunita vědců která se zabývá multiagentními modely se samozřejmě nemůže obejít bez softwarových inženýrů navrhujících architekturu modelovacích nástrojů. Multiagentní modely však využívají zejména vědci, kteří se zabývají problémy přírodních či sociálních věd a snaží se pomocí modelování získat nějaké nové poznatky o reálných systémech. Těžiště pozornosti se proto přesouvá od technické realizace agentů ke sledování, vyhodnocování a interpretaci chování modelů.

I agenty, které jsou řízené velmi jednoduchými pravidly, mohou v některých případech produkovat vysoce komplexní⁵ dynamiku systému. Systémovou komplexitu můžeme formálně chápat jako míru vzájemné závislosti (např. vzájemnou informaci) mezi chováním různých částí systému

⁵ Systémová komplexita je odlišná od výpočetní komplexity i od tzv. algoritmickej komplexity (resp. Algorithmic Information Content, AIC). Komplexita zde také neznamená úplnost či zevrubnost jako např. ve spojení „komplexní přestavba domu“.


v prostoru nebo v čase (Tononi, 1996; Shalizi, 2001). Proces, při kterém se zvyšuje komplexita systému bez koordinovaného vnějšího řízení, se nazývá samoorganizace. Výzkum samoorganizace a koordinovaného chování, které díky ní vzniká, je jedním z hlavních přínosů multiagentních modelů.

V této práci se soustředím na modely sociálních, zejména ekonomických organizací⁶. V tomto kontextu představují agenti⁷ zjednodušené modely některých rolí reálných individuí – např. vzájemná komunikace, šíření nějakého typu chování, zápas o zdroje, prodej a nákup komodit apod. Vhodně navržený model, přesto a někdy právě proto, že je vždy nesmírně zjednodušeným popisem části reality, může odhalit nějakou vlastnost chování zkoumaného systému, kterou je možno zobecnit i na fungování tohoto systému v realitě. Multiagentní modely sociálních systémů pomohly porozumět procesům jako je například evoluce kooperativního a koordinovaného chování, vznik koalic, šíření inovací či tvorba tržních cen.

Multiagentní modely jsou relativně mladou disciplínou, jejíž rozvoj umožnilo až masové rozšíření výkonné výpočetní techniky dostupné od počátku devadesátých let. Metodologické zakotvení této disciplíny se proto dosud tvoří. V následujících kapitolách se proto, zaměřím na definování hlavních prvků metodologie tvorby multiagentních modelů. Nejprve však bude vhodné seznámit se základem multiagentního přístupu na příkladu velmi jednoduchých výpočetních systémů – tzv. celulárních automatů.

2.2. Celulární automaty

Jakýmsi „předchůdcem“ multiagentních modelů, který vhodně ilustruje jejich základní vlastnosti, jsou celulární automaty. Celulární automaty jsou výpočetní systémy, které se skládají z buněk umístěných v jedno, dvou nebo vícerozměrné prostorové struktuře – mřížce. Stav buňky v čase $t+1$ závisí na jejím stavu a stavu jejích sousedů v čase t .



Obr. 1.- Jednorozměrný celulární automat (Wolfram, 2002).


Jednorozměrný celulární automat je systém tvořený řetězcem buněk, které nabývají v hodnot (například 2 hodnot - $\{0;1\}$), přičemž stav buňky v následujícím kroku je určen stavem k jejích sousedů v kroku minulém. Počet možných pravidel, která určují, jak se bude měnit stav buněk, prudce roste s v i k .⁸ Různá pravidla mají různý vliv na chování systému. Pokud například první řetězec

⁶ Dalšími příklady multiagentních modelů jsou modely biologických nebo fyzikálních procesů. Biologické multiagentní modely se často soustředí na problematiku růstu buněčných kolonií, modelování ekologických vztahů, šíření nemocí apod. Ve fyzikálních systémech agenty většinou představují částice nějaké látky, což umožňuje studovat dynamiku takových procesů, jako jsou například turbulence, prosakování porézním materiálem či fázové přechody.

⁷ Pokud termín agent označuje neživé např. softwarové či robotické prvky, je logické chápat ho jako neživotný. V kontextu sociálních systémů však agenty označují živé lidi nebo organizace z lidí složené. Jazykový cit mne v tomto případě vede k tomu, že užívám termín agent jako životný. Přidrží se tohoto životního pojetí agentů i ve zbytku této práce.

⁸ Konkrétně pokud označíme v počet stavů, které mohou buňky nabývat, a k počet buněk, které určují

buněk bude náhodně vygenerovaný a nové řetězce skládáme pod sebe, vzniknou obrazce znázorňující strukturu postupné (samo)organizace náhodně vygenerovaného řetězce. Wolfram (2002) popisuje 4. třídy chování jednorozměrných pravidel.



Obr. 2. Čtyři třídy chování jednorozměrných celulárních automatů (Wolfram, 2002)

První dvě třídy chování vedou k jednoduchému uniformnímu nebo repetitivnímu chování. Pokud bychom počáteční náhodně vygenerovaný řetězec chápali jako fluktuaci vyvolanou vnějším prostředím, pak bychom tyto dvě třídy chování mohli připsat vysoce uspořádaným systémům, nepřiliš citlivým na vnější podněty (jako jsou pevné krystaly), kdy vnější podnět (do nějakého kritického stupně intenzity) je buď zcela utlumen, nebo vede k jednoduché vibraci. Jako celek mohou tyto systémy v průměru nabývat jen málo odlišných stavů.

Zcela naopak je tomu ve třetím případě, kdy systém nepřestává fluktuovat, míra neuspořádanosti systému se nemění.⁹ Tyto systémy jsou velmi citlivé na počáteční podmínky. Jako celek mohou tyto systémy nabývat velmi mnoha stavů. Chování této třídy nazýváme náhodné (random).¹⁰

Čtvrtá třída chování je někde na rozmezí mezi prvními dvěma třídami a třídou třetí. Počáteční náhodná fluktuace je relativně rychle utlumená, ale v některých ostře ohraničených lokálních strukturách přetrvává, může se systémem šířit a interagovat s jinými podobnými lokalizovanými strukturami. Systém selektuje jen jisté stavy vnějšího prostředí (jen jistá uspořádání počáteční fluktuace), tyto stavy vedou ke změnám stavů systému (lokalizované struktury), tyto struktury mezi sebou interagují a tím vytvářejí varianty možných kontextů, ve kterých se mohou objevit nové vstupy z prostředí. Poznamenejme ještě, že interakce lokalizovaných struktur umožňuje výměnu informací mezi částmi systému. Chování této třídy nazýváme komplexní.

Příkladem dvourozměrného celulárního automatu s komplexním chováním je známý Conwayův automat LIFE (Gardner, 1970). Buňky v tomto automatu se řídí následujícími pravidly:


1. Buňky, které mají méně než dva sousedy, zanikají (jsou příliš osamělé).
2. Buňky s více než třemi sousedy zanikají (jsou příliš stísněné).
3. Buňky se dvěma či třemi sousedy přežívají.
4. Prázdná místa s právě třemi sousedními buňkami jsou zaplněna novou buňkou.

nový stav buňky, pak existuje v^{v^k} možných pravidel. Pro automat zobrazený na obr. 1. existuje tedy 256 možných pravidel. Jedno z těchto pravidel tzv. pravidlo 110, je dokonce výpočetně univerzální, tj. je možné sestavit celulární automat s tímto pravidlem, který bude ekvivalentní univerzálnímu Turingovu stroji (Wolfram, 2002).

⁹ Některá pravidla ze 3. třídy (např. tzv. pravidlo 30) vedou ke stochastickým sekvencím buněk i ze zcela uspořádaných počátečních stavů (např. z jedné jediné buňky) a zvyšují neuspořádanost systému, jiná pouze udržují neuspořádanost počátečního stavu. Vývoj celulárního automatu řídí deterministická pravidla. Ale u některých CA (např. zmíněné pravidlo 30) tato pravidla generují i z uspořádaného stavu, kdy je na začátku pouze jediná buňka, sekvenci buněk, která je stochastická podle všech dostupných statistických testů (Wolfram, 2002).

¹⁰ Autoři zabývající se chováním samoorganizujících se systémů většinou rozlišují náhodné a chaotické děje. Teorie deterministického chaosu zkoumá chaotické děje, jejichž deterministický vývoj je určen soustavou nelineárních diferenciálních rovnic, které jsou citlivé na počáteční podmínky. Pravidla určující vývoj samoorganizujících se systémů však mohou být mnohem obecnější.

Tato jednoduchá pravidla vedou vysoce komplexní dynamice. Povšimněme si, že pravidla obsahují vhodně vyváženou pozitivní a negativní zpětnou vazbu (podpora a tlumení růstu buněk). Bylo dokázáno, že LIFE je výpočetně univerzální, tj. při vhodné počáteční struktuře buněk (naprogramování) může provádět výpočty ekvivalentní univerzálnímu Turingovu stroji (Rendell, 2005).



Obr. 3. – Celulární automat LIFE. Vlevo: V prvním kroku byla na ploše pouze tato struktura pěti buněk zvaná F-pentomino. Uprostřed: Po sto krocích se buňky rozšířily a vytvořily komplexní strukturu. Vpravo: Turingův stroj implementovaný v LIFE (Rendell, 2005).

2.3. *Dynamika multiagentních modelů*

Multiagentní modely představují tzv. bottom-up přístup k modelování systémů. Systém je modelován od elementárních aktivních prvků – agentů a teprve díky jejich interakcím je možno odvodit agregátní globální vlastnosti systému jako celku.

Na rozdíl od celulárních automatů, mohou být multiagentní modely podstatně obecnější. Agenty mohou být různorodé – mohou mít odlišné parametry i zcela odlišná funkce, které řídí jejich chování. Tyto funkce mohou být podstatně složitější než u celulárních automatů. Mohou mít vlastní paměť. Nemusí interagovat pouze v prostorových mřížkách, ale v libovolných strukturách.

Také je třeba zmínit, že celulární automaty nemusí modelovat žádný reálný systém, může se jednat o abstraktní výpočetní systémy. Multiagentní modely mají však vždy za cíl modelovat nějaký reálný systém, byť třeba velmi zjednodušeně.

Dynamika multiagentního modelu je určena rekurentními výpočetními funkcemi, které definují chování agentů. Iterování funkcí posune systém o jeden diskretní krok v čase. Řešení funkcí nespočívá v analytickém nalezení rovnovážného bodu systému, ale ve zmapování dynamiky systému. Díky tomu není nutné klást často velmi zjednodušující předpoklady o vlastnostech agentů a jejich interakcí. Multiagentní modely se liší jak od tzv. top-down rekurentních modelů systémové dynamiky, které popisují dynamiku interakcí globálních vlastností systému, tak od analytických modelů, hledajících rovnovážné body systému. Podrobnější rozbor této problematiky provedeme v kapitole o vztahu multiagentních modelů a analytických modelů v ekonomii.

V nejobecnější situaci může být každý i -tý agent sám o sobě otevřeným dynamickým systémem, jehož stav se v čase t dá vyjádřit n -ticí proměnných:

$$a_{i,t} = (x_{i,1}, \dots, x_{i,n_i})$$

Agentem může být i prostředí. Počet i druh proměnných se může lišit u různých agentů. Proměnné mohou být čísla, řetězce, seznamy, pole, ale i procedury apod. Z programátorského hlediska je agent většinou reprezentován jako objekt.

Chování agenta v systému, kde existuje k jiných agentů, je dáno rekurentní funkcí:

$$f_i(a_{1,t-1} \dots a_{k,t-1}) = [a_{i,t}, B(a_i, t)]$$


Člen $B(a_i, t)$ označuje množinu případných potomků agenta i vytvořených v čase t . Tato množina může být prázdná a nesmí obsahovat již existující agenty.

Funkce nemusí být spojité (typicky mohou obsahovat rozhodování typu IF-THEN) a mohou být stochastické. Funkce mohou být velmi složité a mohou zahrnovat různé metody umělé inteligence. Agenti mohou vznikat i zanikat. Chování agenta nemusí být závislé na všech agentech v systému, ale jen na agentech, kteří s ním v nějakém smyslu lokálně „sousedí“. To, se kterými agenty agent sousedí, se může v čase měnit.

Celková dynamika systému je výsledkem paralelní nebo sekvenční iterace funkcí definujících chování všech agentů. Při paralelní iteraci jsou stavy agentů změněny zároveň a stav agenta v čase t je vypočítán vždy na základě stavů agentů v čase $t-1$. Z hlediska počítačového programu není samozřejmě možné změnit stav agentů zároveň, a je nutné použít pomocné proměnné uchovávající stav agenta v minulém i současném kroku.

Při sekvenční iteraci jsou postupně iterovány funkce náhodné permutace agentů (buď všech, nebo části), takže se může stát, že stav agenta v čase t je vypočítán na základě stavu některých agentů v čase $t-1$ a některých v čase t (jejich funkce již byly v tomto kroku iterovány). Sekvenční iterace tedy přináší do modelu prvek náhody, který může zásadně ovlivnit dynamiku modelu. Někdy odpovídá sekvenční iterování lépe reálnému chování agentů¹¹

Jako příklad uvádím model, ve kterém hrají agenti se svými sousedy ve 2D mřížce opakované věžňovo dilemma (viz kapitola 4.) Agenti přijímají strategii svého souseda, který má největší zisk. Pro jisté hodnoty výhody z nekooperativního chování se v mřížce objeví složité dynamické vzorce kooperativní a nekooperativní strategie, které můžeme znázornit odlišnými barvami. Původní model (Wilensky, 2002) byl iterován sekvenčně a díky prvku náhody vznikaly nepravidelné vzorce. Upravil jsem model tak, aby byl iterován paralelně a objevily se vzorce symetrické.



Obr. 4. Sekvenční (vlevo) a paralelní (vpravo) iterování funkcí agentů při opakovaném věžňově dilematu ve 2D mřížce při stejných hodnotách výhody nekooperativního chování.

¹¹ Sekvenční iterování je použito například v modelu finančního trhu (v druhé části této práce), kde agenti sledují názory okolních agentů, a přitom neví, jestli tito agenti již v daném kroku svůj názor změnili (jejich stav je v čase t), nebo zda mají ještě názor z kroku minulého (v čase $t-1$).

2.4. Zásady multiagentního modelování

2.4.1. Tvorba modelu

Americký statistik George E. P. Box napsal, že modely jsou vždy chybné, ale někdy mohou být užitečné (Box a Draper, 1987). Měl tím na mysli to, že modely jsou vždy zjednodušující abstrakcí. Popisujeme jen ty části reality, které jsou pro nás důležité, a jen tak podrobně, jak nám to umožňují technická omezení. Užitečné jsou ty modely, které můžeme využít pro lepší rozhodování. Užitečné modely nám pomohou orientovat se v realitě podobně, jako nám dobrá mapa pomáhá orientovat se v terénu - dokážeme předpovědět, že když půjdeme po této cestě, dojdeme do cíle. Neužitečné modely nám v lepším případě neřeknou nic nového a pouze plýtvají naším časem, v horším případě nám nabízejí chybné předpovědi ohledně chování reality. Aby modely, které vytváříme, nebyly zbytečné nebo zavádějící, je nutné dodržet několik základních pravidel, které se mohou zdát samozřejmé, ale často se na ně zapomíná.

V první řadě je potřeba jasně stanovit, jaký problém chceme řešit a čeho chceme modelem dosáhnout. Při důkladnějším rozboru můžeme zjistit, že vůbec žádný model nepotřebujeme. Je dobré prostudovat literaturu a zjistit, zda podobný model nevytvořil již někdo jiný.

Důležité je uvědomit si, zda je model určen k predikci konkrétních dat v reálném prostředí, nebo zda jde o výzkumný model, který má přinést vhled do fundamentálních zákonitostí dynamiky nějakého systému.

V prvním případě zkoumáme, např. jak se bude vyvíjet míra nezaměstnanosti v příštím čtvrtletí, nebo ve které části města se dá očekávat dopravní zácpa. Dobrým příkladem takového modelu je model trhu s elektřinou, přehled literatury viz (Sensfuß et. al., 2007). V těchto případech je třeba, aby model byl co nejvěrnější, což vyžaduje většinou složitý model se širokou škálou různých parametrů.

Naopak výzkumné modely musí být natolik jednoduché, abychom dokázali zjistit, jak systém vytváří výsledné chování. Je tedy vhodné u těchto modelů počet parametrů omezit jen ty nejzákladnější.

Na začátku modelování je třeba zvolit škálu modelu. Co je základním prostorovým prvkem modelu? Jaký časový interval reprezentuje základní časový krok modelu a jak daleko do budoucnosti chceme chování systému modelovat. Dále musíme určit, jaké prvky reality do modelu zahrneme (extenzivní hranice) a jak podrobně je popíšeme (intenzivní hranice).

Vždy bychom měli začínat s jednoduchými modely (tzv. prototypy) a ty postupně rozšiřovat o nové vlastnosti. Cílem by mělo být vytváření modelů tak jednoduchých, jak je to jen možné, ale ne jednodušších. Příliš složité modely se obtížně verifikují (viz níže) a zahrnou nás ohromným množstvím nepřehledných dat. Ovšem příliš jednoduché modely mohou ztratit kontakt s realitou. Měli bychom identifikovat klíčové části, parametry a procesy modelu.

Nyní můžeme vybrat vhodný modelovací nástroj (viz kapitola 2.7) a vhodné datové struktury a procedury pro popis našeho modelu. Základním požadavkem, který je kladen na softwarový model (nejen multiagentní) je jeho spolehlivost, tj. jde o to, aby výsledky, které model prezentuje, nebyly důsledkem chyb programu nebo nějakých artefaktů typu zaokrouhlovacích chyb apod. Spolehlivost modelů je možno ověřit nejlépe tím, že se je někdo pokusí nezávisle vytvořit znovu, popřípadě je autor reimplementuje v jiném vývojovém prostředí¹². K tomu přispívá zejména jednoduchost modelu a dostupnost dobré dokumentace a komentovaného zdrojového kódu.

Relativně dlouhou dobu zabere „hraní si“ s modelem – experimentování s různými hodnotami parametrů. Při tom provádíme verifikaci modelu – tj. zkoušíme, zda se model chová tak, jak

¹²

Například model evoluce averze k riziku a nejistotě popsaný v druhé části této práce byl původně vytvořen v Javě s využitím knihoven REPAST, ale později jsem ho reimplementoval v NetLogu. Model se choval zcela totožně, což potvrdilo, že konceptuální model byl správně softwarově implementován.

očekáváme (víceméně zkoušíme, zda jsme ho správně naprogramovali). Nakonec je nutno zpracovat vygenerovaná data a provést jejich statistickou analýzu.

2.4.2. Typy agentů

Agenty se většinou rozdělují na dva typy: reaktivní a deliberativní (nebo též někdy inteligentní).

Agenty u nichž není kladen důraz na symbolickou reprezentaci vnějšího světa a sofistikované rozhodování bývají označovány jako reaktivní. Chování (nikoliv stav) čistě reaktivních agentů není závislé na minulých stavech agentů či prostředí.

Příkladem čistě reaktivních agentů jsou buňky celulárních automatů. Stavy agentů jsou závislé na jejich minulých stavech a minulých stavech okolních agentů. Tato závislost (resp. chování agentů) je popsána neměnnou předem danou sadou pravidel typu IF-THEN. Všechny buňky se chovají stejně a své chování nemohou v průběhu modelu měnit.

Složitějším typem reaktivních agentů jsou například agenti použítí v modelu evoluce etnocentrického chování (viz kapitola 4). Na rozdíl od celulárních automatů mohou tito agenti mít různé typy jednoduchého chování, ale jejich chování se již v průběhu života nemění. Tito agenti však mohou umírat a jsou schopni reprodukce, jejíž pravděpodobnost je závislá na vzájemné interakci agentů. Potomci dědí mutované parametry svých rodičů. Komplexita těchto evolučních modelů je výsledkem vzniku a rozmnožování nových typů chování.

Jiným typem složitějších reaktivních modelů je model opakovaného věznova dilematu ve 2D mřížce popsaný v předchozí kapitole. Agenty jsou vybaveny užitkovou funkcí, kterou se snaží maximalizovat pomocí jednoduché heuristiky. Heuristika spočívá v tom, že agenty v každém kole vyhodnotí stavy svých sousedů, a zvolí typ chování, který použil agent, který získal v minulém kole největší užitek.

Deliberativní agenty mohou disponovat bohatou symbolickou reprezentací vnějšího prostředí a využívat metody tradiční umělé inteligence a strojového učení (včetně konekcionistických systémů, např. neuronových sítí apod.). Většinou jsou deliberativní agenti vybaveni předem danou funkcí užitku nebo výkonu, kterou se snaží maximalizovat. K nalezení chování, které maximalizuje užitkovou funkci, je velmi často využíváno učení pomocí odměny a trestu (reinforcement learning). Přehled této problematiky je možno najít např. v (Kubík, 2004).

Je zřejmé, že mezi reaktivními a deliberativními agenty není ostrý předěl. Rozdíl je zejména v množství paměti, kterou agent disponuje, a ve složitosti algoritmů, které analyzují vstupy z prostředí v kontextu znalostí uložených v paměti. Existují také hybridní agenty, které se v některých situacích chovají reaktivně (například když je třeba se rozhodnout velmi rychle) a v jiných deliberativně.

Zvláštním typem deliberativních agentů jsou tzv. agenty kognitivní – tj. agenty, které disponují nějakým sofistikovaným psychologickým modelem lidského chování jako je např. ACT-R, Soar (založené na symbolické reprezentaci znalostí) či Clarion (založené na hybridní symbolické i subsymbolické reprezentaci znalostí) (Sun, 2006). Tyto deliberativní agenti se mohou vyznačovat vysokou mírou autonomie. Nemusí mít například předem stanovené užitkové funkce, ale mohou si je vytvářet sami. Nebo mohou být schopni plánovat své akce na mnoho kroků dopředu a v průběhu realizace plánu, při zjištění nových skutečností, jsou schopni svůj plán modifikovat.


Sofistikované chování deliberativních agentů je ovšem velmi náročné na výpočetní výkon. To v praxi omezuje maximální počet takto náročných deliberativních agentů v multiagentním modelu.

2.4.3. Interpretace chování modelu

Statistická analýza může odhalit zajímavé a nečekané chování systému nebo naopak potvrdit naše předpoklady. Zejména je důležité, zda je chování modelu robustní – tj. podobné pro široké rozmezí počátečních hodnot parametrů, nebo zda existují kritické hodnoty parametrů při kterých se (často dramaticky) mění chování systému – dochází k fázovému přechodu.

Pro správnou interpretaci chování modelu je nutno identifikovat vlastnosti modelu, které vedly k pozorovanému chování. Macy a Willer (2002) uvádějí následující hlavní vlastnosti, na které je třeba se při interpretaci modelů zaměřit.

Je třeba rozlišit typy interakcí mezi agenty. Komunikují agenty přímo mezi sebou nebo komunikují přes prostředí? Pokud přímo, odpovídají ihned na podněty nebo mají nějakou frontu, do které se podněty řadí podle určitých kritérií? Jsou interakce mezi agenty prostorové a lokální (např. dvourozměrná mřížka)? Jsou určeny sociální sítí či jinou komplexní strukturou (viz obr. 5)? Nebo mohou interagovat všechny agenty se všemi? Může agent na základě nějakých charakteristik volit, zda bude s druhým agentem interagovat? Může se síť interakcí mezi agenty měnit, například důsledkem jejich pohybu, změn preferencí, přidávání a odebírání agentů?



Obr. 5. Interakce v mřížce a některé komplexní struktury interakcí mezi agenty. V mřížce je vlevo nahoře vyznačeno von Neumannovo okolí a vpravo dole Moorovo okolí.

U deliberativních agentů, které jsou schopny adaptace a učení, je třeba tento mechanismus podrobně specifikovat. Je adaptace agentů založena na individuálním učení, imitaci okolních agentů, evoluci celé populace či jejich kombinaci? Jaký konkrétní algoritmus učení agentů je použit (učení typu odměna a trest např. Q-learning, Bayesovské učení, nějaký typ neuronové sítě apod.)? Pokud agent imituje chování okolních agentů, jde jen o vnější napodobení nebo kopíruje i části kódu, který chování agenta generuje? Jaké je kritérium pro selekci agentů při umělé evoluci – jde o schopnost bojovat o zdroje nebo spíše o sociální vliv?

2.5. Logika a cíle modelu

Multiagentní modely jsou někdy označovány za nový způsob vědeckého výzkumu (Axelrod, 2003). Mohou reprezentovat všechny tři základní způsoby logického usuzování, které věda používá, tedy dedukci, indukci a abdukci.¹³ U některých jednodušších modelů může získat jeden typ usuzování klíčový význam. To se týká většiny modelů použitých v této kapitole jako ilustrace. U složitějších modelů však většinou hrají všechny uvedené způsoby usuzování stejně významnou roli. Vždy bychom si však měli uvědomovat, který typ usuzování právě používáme.


¹³

Tyto způsoby usuzování můžeme ilustrovat na příkladu tří tvrzení: „Prší.“, „Když prší, je mokro.“, „Je mokro.“. Pokud odvozujeme z příčiny „Prší.“ a z obecného pravidla „Když prší, je mokro.“ důsledek „Je mokro.“, jedná se o dedukci. Dedukce vede k nutnému závěru. Pokud odvozujeme z příčiny „Prší“ a důsledku „Je mokro“ obecné pravidlo „Když prší je mokro“ jedná se o indukci. Indukce je vždy jen pravděpodobná, její spolehlivost je dána počtem provedených pozorování. Pokud z obecného pravidla „Když prší je mokro.“ a důsledku „Je mokro.“ odvozujeme příčinu „Prší.“ jedná se o abdukci. Abdukce je vždy jen zkusmý, ale nikoliv zcela náhodný pokus najít správnou příčinu (Není náhodou mokro proto, že pršelo?). Není zaručeno, že výsledek abdukce je správný, v našem případě může být mokro proto, že právě projel kropicí vůz apod.

2.5.1. Dedukce

Při dedukci odvozujeme z nějaké počáteční sady předpokladů a pravidel důsledky. V multiagentních modelech představují počáteční předpoklady hodnoty parametrů modelu a pomocí pravidel chování jednotlivých agentů z nich odvozujeme stav systému v následujícím kroku. Pokud je model stochastický, odvozujeme pravděpodobnostní distribuci možných výsledků. V tomto případě je nutno spustit model tolikrát, abychom získali dostatek údajů pro statisticky spolehlivý odhad této distribuce.


Příkladem multiagentních modelů, pro které je klíčová dedukce, je predikce chování reálných systémů. Bonobea (2002) identifikuje tři hlavní oblasti, kde je možné využít multiagentní modely pro predikce chování konkrétních sociálních systémů. Je to modelování toků, trhů a organizací. Mezi příklady modelování toků patří např. dynamika evakuace osob a modelování dopravy. Modelování evakuace osob ukázalo, že některé architektonické prvky mohou přispět ke zrychlení evakuace osob. Překvapivé je, že např. umístění sloupu před vchod zpomalí a roztříští tok spěchajícího davu, a tím brání, aby lidé v panice vchod ucpali. Modelování dopravy patří mezi nejúspěšnější aplikace multiagentních modelů. Tyto modely umožňují relativně snadno predikovat jaký vliv na dopravu (např. zda vznikne dopravní zácpa) bude mít modifikace komunikací, poruchy či změny světelné signalizace nebo změny legislativní regulace provozu.



Obr. 6. - Modely toků. Vlevo: Model dopravy (Wilensky, 2002) - v pravoúhlých jednosměrných ulicích došlo při vypnutí semaforů k „zaseknutí“ dopravy - žádné auto se nemůže pohnout vpřed. Vpravo: Model evakuace osob (Helbing et. al, 2000) –žluté body jsou osoby, zelené body jsou zraněné osoby : a) evakuace bez sloupu před východem b) evakuace se sloupem po 10. sek. c) evakuace se sloupem po 20. sek. Při evakuaci se sloupem nedochází ke zranění a uniká více lidí.

Multiagentní modely trhů se týkají řady často dosti odlišných aspektů. Jsou to například neočekávané důsledky, které mohou na trh mít změny v legislativě nebo v psychologii účastníků trhu, výpadky v dodavatelsko-odběratelských řetězcích, vliv monopolního postavení na trhu, šíření inovací. Mnoho modelů se také zabývá modelováním finančních trhů a identifikováním faktorů, které mohou vést k nestabilitě cen a trhů. Podrobněji se využitím multiagentních modelů v ekonomii zabývá následující kapitola 3. Také tři podrobně rozebrané modely v druhé části této práce spadají do této oblasti.

Multiagentní modely organizací jsou, na rozdíl klasických procesně orientovaných modelů, schopné lépe vystihnout dynamiku závislou na jednotlivcích, což se týká například modelování tzv. operačního rizika (selhání zaměstnanců, chyby, zpronevěra apod.) nebo modelování vlivu různých typů organizace práce na efektivitu práce. Navíc jsou multiagentní modely díky své názornosti snadno srozumitelné manažerům a zaměstnancům, kteří mohou lépe přispět při jejich tvorbě i interpretaci.



Obr. 7.- Modely organizací. Vlevo: Model řízení projektů v softwarové firmě (Sekerka, 2009). Pracovníci jsou přidělováni k různým projektům a podprojektům podle své kvalifikace. Model zkoumá vliv různých typů organizace práce na efektivitu (náklady na projekt a včasnost dokončení projektu). Vpravo: Model tvorby týmů (Bakshy a Wilensky, 2007). V každém kroku modelu vzniká nový tým, který může být složen ze zcela nových pracovníků, či z pracovníků, kteří již jsou zapojeni v jiných týmech, pracovníci mají tendenci přivádět do nového týmu své kolegy z jiných týmů.


2.5.2. Indukce

Při indukci zobecňujeme známá empirická data a snažíme se zkonstruovat obecná pravidla, která by je dokázala co nejvěrněji generovat¹⁴. V případě multiagentních modelů známe například typickou distribuci hodnot nějakých parametrů u reálných agentů a snažíme se najít taková pravidla chování agentů, která by vedla ke stejné distribuci. Nalezený model by měl být robustní, tj. pro široké rozmezí hodnot počátečních parametrů by se výsledná distribuce hodnot neměla zásadně měnit.

Příkladem může být snaha biologů vysvětlit, jakým způsobem jsou ptáci nebo ryby schopny vytvářet hejna, která nemají žádného vůdce, ale přitom udržují tvar, směr a vyhýbají se překážkám. Modely ukazují, že pro takové chování stačí, aby agenti dodržovali jen několik málo jednoduchých pravidel: snaží se udržet uprostřed hejna a zároveň si udržet odstup od sousedů, snaží se zachovat stejný směr a rychlost, jako jejich sousedé, ale přitom se vyhýbat překážkám apod. (Reynolds, 2001). Jiným příkladem z oblasti biologie je formování mravenčích cest. Mravenci uvolňují do prostředí různé feromony, které označují například cestu k potravě nebo zpět do mraveniště. Pouhá schopnost pohybovat se po gradientech feromonových stop umožňuje mravencům samoorganizovaně „vytvořit“ a udržovat efektivní formu transportu potravy do mraveniště.


14

Jiný důležitý způsob jak využíváme u multiagentních modelů induktivní usuzování, se týká statistického zpracování dat, které multiagentní modely generují. Nemůžeme spouštět model pro všechny hodnoty všech parametrů. Můžeme spustit model s nějakým vzorkem počátečních hodnot parametrů a z vygenerovaných dat poté usoudit na obecný statistický model, předpovídající s přesně určitelnou spolehlivostí rozmezí v jakých se budou pohybovat vygenerovaná data i pro netestované počáteční hodnoty parametrů.



Obr. 8. – Induktivní modely. Vlevo: Model mraveniště (Wilensky, 1997c). Mraveniště je uprostřed, bílé oblasti jsou samoorganizované feromonové stopy vedoucí ke zdrojům potravy. Vpravo: Model formování hejn (Wilensky, 2005).

Typickým induktivním modelem je model vzniku společenské nerovnosti, který vytvořil Epstein a Axtell (1996) pod názvem „Sugarscape“. Na obrázku 9. vlevo vidíme, že agenti (červené tečky) se v tomto modelu pohybují v prostředí, které je na různých místech různě úrodné (různá intenzita růžové). Agenti se v každém kole snaží přesunout na pole s co největším množstvím úrody, kterou sklídí – sklizená úroda tvoří jejich bohatství (v původním modelu se jednalo o cukr – agenti spíše než lidi si původně představovali společenství bakterií nebo hmyzu). Agenti mají odlišné kognitivní schopnost – liší se ve vzdálenosti, kam jsou schopni dohlédnout. Někteří agenti proto zvyšují své „bohatství“ rychleji než druzí, neboť lépe vidí, kde je větší množství úrody. Agenti se navíc liší náročností svého metabolismus, který zpracovává nalezenou úrodu (to modeluje odlišné sklony ke spotřebě). Výsledkem interakcí mezi agenty je distribuce bohatství mezi agenty, která odpovídá nerovné distribuci bohatství v reálném světě. Ukazatele nerovnosti vidíme na obrázku 9. vpravo. Nahoře je distribuce bohatství mezi agenty. Uprostřed je tzv. Lorenzova křivka znázorňující kumulativní bohatství agentů seřazených zleva doprava od nejchudších po nejbohatší (kdyby byli všichni agenti stejně bohatí byla by Lorenzova křivka totožná s přímkou identity). Dole vidíme vývoj Giniho indexu, který je podílem plochy mezi Lorenzovou křivkou a přímkou identity a plochou pod přímkou identity.




Obr. 9. – Model nerovnosti ve společnosti „Sugarscape“.

Jiným příkladem je model vzniku občanských nepokojů, který vytvořil Epstein (2002). Tento model spojuje induktivní návrh mechanismu vzniku nepokojů a deduktivní predikci společenského vývoje při různých typech politického rozhodování. V modelu se na dvourozměrné ploše pohybují různě nespokojení občané a policisté. Pokud se více nespokojených občanů ocitne pohromadě a v dohledu nejsou policisté, jejich nespokojenost vzrůstá a může přejít do otevřené rebelie. Nespokojenost vrůstá také při snižování důvěryhodnosti vlády (např. v důsledku korupce). Policisté zatýkají a na omezenou dobu vězní rebely a snaží se tak zabránit, aby rebelování nezachvátilo většinu populace. Epsteinovi se podařilo mimo jiné ukázat, že při pozvolném snižování důvěryhodnosti vlády na nulu nedojde k velké rebelii. Když ale důvěra poklesne skokově, stačí k vyvolání velké rebelie mnohem menší pokles důvěry než při jejím postupném snižování.

Epsteinův model ilustruje obrázek 10. V levém sloupci, nahoře a dole, vidíme dvě různé situace. Nahoře je situace, kdy žádný agent nerebeluje. V levé části je mapa situace, jak se jeví navenek, vidíme samé modré, nerebelující agenty. Mezi nimi jsou roztroušeni černí policisté. V pravé části levého sloupce je ta samá mapa, ale sytost barev označuje míru subjektivní nespokojenosti agentů. Dole je situace, kdy propukají lokální rebelie. V levé části vidíme, že se objevují hloučky rebelujících, červených agentů. V pravé části opět vidíme míru nespokojenosti agentů.

Pravý sloupec: Nahoře vidíme vývoj situace, při které byla postupně snižována důvěryhodnost vlády (šedá linie) až k nule. Plynule stoupal počet zatčených rebelů (černá linie), avšak nikdy nedošlo k prudkému nárůstu volných rebelů (červená linie). Dole vidíme situaci, při které byla skokově snížena důvěryhodnost vlády o 30%. V důsledku toho došlo k rebelii (ostrý vzrůst červené linie), která byla následně potlačena (pokles červené linie) a rebelové byli pozatýkáni (ostrý růst černé linie).



Obr. 10. – Rebelující občané v Epsteinově modelu.

Na abdukci byl kladen důraz také v jednom z prvních multiagentních modelů, Schellingově modelu rasové segregace (Schelling, 1978). Na konci šedesátých let došlo v USA ke zrušení legislativy, která v některých státech USA vytvářela bariéru mezi rasami. Pozdější laureát Nobelovy ceny za ekonomii, Thomas Schelling, si všiml, že nedošlo k žádným výrazným změnám v rasové segregaci, která se projevuje např. velikostí a uzavřeností městských ghett, kde žijí téměř výhradně jen rodiny jedné rasy. Vytvořil jednoduchý model, který zprvu tvořila jen šachovnice, která představovala město, a mince různé hodnoty představující rodiny různých ras. Rodiny se stěhovaly na náhodné volné


místo, pokud procento jejich sousedů jiné rasy bylo vyšší než hodnota parametru, který můžeme chápat jako jejich rasovou snášenlivost. Schelling zjistil, že i při snášenlivosti 30%, tedy i když rodinám nevadí, že je v okolí méně než třetina rodin stejné rasy, dochází k segregaci ras do ghet. Schellingův model lze obohatit o další prvky. Výsledky vidíme na obrázku 12. Zkoumal jsem situaci, kdy jedna rasa bude výrazně minoritní, a dále situaci, kdy ve městě bude více ras či etnik.

Ve všech případech byla snášenlivost nastavena na 30%. V první řadě je výsledek segregace pro (zleva doprava): Dvě stejně početné rasy, dvě rasy (červená je minoritní a tvoří jen 20% celkové populace), pět ras či etnik.

Ve spodní řadě vlevo je graf ukazující míru uzavřenost ghet pro dvě rasy, z nichž první je minoritní a její podíl na populaci se mění od 5 do 50 procent. Uzavřenost měřím jako procento rodin (v rámci jedné rasy), které jsou zcela obklopeny rodinami stejné rasy. U minoritní rasy je uzavřenost vyšší než u majoritní, až do velikosti 15% podílu na populaci, potom už je rasa tak malá, že nedokáže tvořit větší gheta a naopak majoritní společnost vytváří uzavřené oblasti díky svému počtu.

Ve spodní řadě vpravo je graf ukazující míru segregace pro různý počet stejně velkých ras či etnik. Míru segregace měřím jako procento sousedních rodin, které jsou stejné rasy, jako rodina uprostřed. Vidíme, že s počtem etnik roste i míra segregace.

Na obou grafech označují horní a dolní meze 90% interval spolehlivosti odhadu průměrné hodnoty z 20 běhů modelu.



Obr. 12. – Schellingův model segregace a jeho modifikace.


2.5.3. Abdukce

Při abdukci známe předem jak obecná pravidla chování systému, tak i možné důsledky chování, ale zajímají nás počáteční předpoklady, které k danému výsledku vedou. Abdukce v případě

multiagentních systémů znamená hledání hodnot parametrů modelu, které povedou k očekávanému chování. Často například hledáme hodnoty parametrů, při kterých nastává zajímavá změna dynamiky systému, kterou můžeme chápat jako analogii fázového přechodu u fyzikálních systémů. Většina nástrojů pro tvorbu multiagentních modelů disponuje nástroji pro automatizované opětovné spouštění modelů pro různé hodnoty parametrů a jejich kombinací.

Příkladem abdukce může být model požáru lesa, kdy hledáme kritickou hodnotu parametru, který určuje hustoty lesního porostu. Při nižší hustotě porostu se oheň nerozšíří, pokud však hustota přesáhne jistou hranici, plocha zasažená ohněm skokově naroste - oheň se rozšíří téměř po celém lese.

V epidemiologii se užívají modely, které umožňují sledovat šíření infekce při interakci mezi agenty pohybujícími se v prostoru nebo v sociální síti. Častým cílem bývá najít kritické hodnoty parametrů, při kterých se v populaci začnou šířit epidemie. V případě šíření pohlavních chorob jde např. o průměrnou délku vztahů, ochotu užívat kondom, jak často si jedinci nechávají dělat testy apod.




Obr.11. – Abduktivní modely. Vlevo: Model lesního požáru (Wilensky, 1997a). Vpravo: Model šíření AIDS. Zelení agenti jsou zdraví, modří jsou nakažení a neví se o tom, červení jsou nakažení a ví se o tom. (Wilensky, 1997b).

Velmi podobným příkladem v ekonomii je šíření nějakého typu chování (např. šíření nějaké herní strategie, politického názoru, nové technologie či módního výrobku apod.). Předpovídat např. zda se nějaký konkrétní výrobek stane hitem, je při komplexitě spotřebitelských preferencí téměř nemožné (Bonobea, 2002). Naopak se dá velmi dobře ukázat, že pro různé struktury společenských vazeb se může významně lišit dynamika šíření výrobku (rychlost, skokové změny apod.).

2.6. *Komplexita, samoorganizace a kognice*

Multiagentní modely jsou velmi často (ale ne vždy) komplexním systémem. Komplexitu můžeme rozdělit na strukturální a funkční (nebo dynamickou). Strukturálně komplexní systém sestává z mnoha částí, mezi nimiž je relativně mnoho vazeb (typicky je ve strukturálně komplexním systému podstatně více vazeb než prvků). Funkčně komplexní systém vykazuje dynamiku, která je výsledkem nelineárních interakcí mezi agenty – výsledek interakcí tedy není prostým součtem chování jednotlivých agentů. To je většinou důsledkem existence zpětných vazeb v systému.

Podle (Langton, 1990) je komplexita mírou množství pravidelnosti v systému. Komplexita tedy bude nízká jak u zcela náhodných systémů, kde na úrovni celku žádné pravidelnosti nepozorujeme, tak u vysoce uspořádaných systémů, kde se projevuje jen málo druhů pravidelnosti. Komplexní systémy se vágně řečeno pohybují na hraně náhody a řádu. Formálně lze míru komplexity vyjádřit jako míru vzájemné závislosti (např. vzájemnou informaci) mezi chováním různých částí systému v prostoru nebo v čase (Tononi, 1996; Shalizi, 2001). Jinými slovy v komplexním systému mnoho různých typů změn v jedné části systému významně ovlivňuje změny v jiné části systému.



Obr. 13. – Nemotónnosť systémové komplexity. Vlevo: Komplexita je nízka pro jednoduché struktury. Vpravo: Komplexitou je nízka pro zcela náhodné (zašuměné) struktury. Uprostřed: Komplexita je vysoká pro struktury obsahující mnoho pravidelností (zde Duchampův futuristický „Akt sestupující ze schodů“ zachycující několik fází figury v čase)

Samovolné zvyšování komplexity, bez koordinovaného vnějšího řízení se nazývá samoorganizace. Samoorganizace bývá důsledkem existence vyváženého řetězce vzájemně propojených pozitivních i negativních zpětných vazeb. Někdy je místo pojmu samoorganizace používán mnohem vágnější termín *emergence*¹⁵ nebo *emergentní jev*. Někteří autoři chápou emergenci jednoduše jako důsledek samoorganizace (Corning, 2002; Goldstein, 1999).

Díky samoorganizaci můžeme pochopit sociální jevy jako je formování hejna ptáků, chování mraveniště, nebo formování organizací. Hejno, mraveniště nebo jiné sociální systémy mohou být modelovány za pomoci reaktivních agentů s velmi omezenými kognitivními schopnostmi, ale celek přitom může vykazovat samoorganizovanou kolektivní kognici. Celek dokáže prozkoumávat své okolí, přizpůsobovat se mu a případně z něj efektivně získávat zdroje k přežití. Reprezentace vnějšího prostředí není jednoznačně vázána na skupiny symbolů uložených v systému (tak je kognice chápána v tradiční umělé inteligenci), ale je v systému distribuovaná subsymbolicky a je většinou silně zašuměná.

Širší metodologický rámec pro tuto problematiku nabízí např. (Maturana a Varela, 1980), kteří chápou kognitivní proces zcela obecně, jako schopnost živých organismů udržovat svoji komplexní integritu a autonomii. To je umožněno právě schopností reagovat a adaptovat se na změny prostředí pomocí samoorganizované aktivity částí organismu (části mohou na různých úrovních popisu představovat např. organické makromolekuly, buňky nebo orgány). Podobný přístup navrhuje např. i (Kauffman, 1996). Podrobnější rozbor pojmu samoorganizace interpretovaného jako kognice autonomních agentů je možno najít v (Burian, 2006). Samoorganizovanou kognici je možno chápat jako aktivní schopnost agenta či society agentů rozpoznávat změny prostředí významné pro udržení jeho/jejich integrity, udržovat svoji integritu, reagovat na změny prostředí, adaptovat se na ně a ovlivňovat prostředí.

¹⁵

V kontextu komplexních dynamických systémů mluvíme většinou o tzv. slabé emergenci nikoliv o filosofickém pojmu silné emergence, který je užíván např. k vysvětlování interakce ontologických kategorií mysli a těla.

Samoorganizovanou societu agentů můžeme považovat za metaagenta, který se pohybuje v prostředí, ve kterém může existovat několik podobných metaagentů. Metaagenty se mohou vzájemně rozpoznávat, interagovat spolu, kooperovat či soupeřit apod. Moji studenti například vytvořili model¹⁶, ve kterém mezi sebou bojují o potravu dvě mraveniště. Zkoumali, jakým způsobem se projeví různé typy handicapů na výkonnosti mraveniště. Metaagenty se samozřejmě také mohou organizovat do societ. Může vznikat hierarchie agentů, kdy vyšší úrovně agentů jsou tvořeny samoorganizovanými societami agentů z nižší úrovně.

2.7. Nástroje

2.7.1. Vlastnosti nástrojů pro tvorbu multiagentních modelů

Multiagentní modely jsou většinou vytvářeny pomocí specializovaných vývojových prostředí. Podrobné srovnání různých nástrojů pro multiagentní modelování lze nalézt v (Railsback et. al., 2006). Nejčastěji jde o soubory knihoven vytvořených v nějakém objektově orientovaném jazyce jako je JAVA nebo C, které obsahují funkce usnadňující tvorbu agentů a prostředí, časování akcí, grafickou prezentaci a ovládací rozhraní, sběr dat a jejich základní statistické vyhodnocení. K ovládání těchto nástrojů je třeba znalost programování v příslušných programovacích jazycích. Příkladem takového nástroje je REPAST (2010). V posledních verzích poskytuje REPAST integrované vývojové prostředí tzv. REPAST Symphony.

2.7.2. NetLogo

Jelikož většina modelů v této práci byla vytvořena ve vývojovém prostředí NetLogo (2010), popíši toto prostředí podrobněji.

NetLogo disponuje speciálním programovacím jazykem, který je odvozen z jazyka Logo. NetLogo je díky své jednoduchosti vhodné pro účely výuky¹⁷ a pro vědce, kteří nejsou profesionálními programátory. Nutnost umět programovat brzdí rozšíření multiagentních systémů mezi vědci z oblasti sociálních věd. Možná ale nastává čas, aby základní kurzy programování začaly být běžnou součástí vzdělání ekonomů či sociologů. Ke snadnému osvojení NetLoga přispívá i skutečnost, že obsahuje velmi podrobnou dokumentaci, tutoriály a rozsáhlou knihovnu ilustračních modelů z mnoha různých disciplín. Z této knihovny čerpám i v této kapitole. NetLogo je distribuováno zdarma.

Hlavní výhodou NetLoga je velmi jednoduché vytváření komunikačního rozhraní s uživatelem pomocí tlačítek, přepínačů, posuvníků a dalších ovládacích prvků. V komunikačním rozhraní je možné snadno umístit okna, ve kterých uživatel sleduje v reálném čase vytvářené grafy, které zachycují vývoj uživatelem vybraných proměnných. Důležitou součástí komunikačního rozhraní je grafický výstup, ve kterém se zobrazuje pohyb a stav agentů. NetLogo má předem připravenou sadu instrukcí pro pohyb agentů ve dvourozměrné mřížce a síťových strukturách. Existuje i 3D verze NetLoga, která umožňuje i třírozměrný pohyb a zobrazení agentů. Dokumentace k modelu je integrována přímo do modelu. Stejně tak je do modelu integrován i editor programového kódu. Kód je interpretovaný a nikoliv kompilovaný, takže je velmi snadné ho rychle upravovat. NetLogo je možno ovládat i interaktivně (dokonce i za běhu modelu) pomocí příkazového řádku. Ve vývojovém prostředí jsou integrovány i základní debugovací nástroje.

Díky své jednoduchosti je NetLogo vhodné pro rychlé vytváření jednodušších prototypových modelů. Přitom jde o plnohodnotný programovací jazyk. Umožňuje například inkludivat do zdrojového kódu externí kód, načítat a ukládat data z a do souborů na disku. K dispozici jsou i instrukce pro snímání grafického výstupu ve video formátu QuickTime. Vývojové prostředí obsahuje i aplikaci HubNet, která umožňuje komunikaci mezi jednotlivými NetLogo modely přes počítačovou


¹⁶ Autory modelu jsou Pavel Trejbal a Jan Procházek. Model je na disku přiloženém k této práci.

¹⁷ Podílel jsem se na projektu tzv. „Školy učitelů informatiky“, která vzdělává učitele základních a středních škol a učí je používat při výuce NetLogo modely přeložené do češtiny, viz (Robotomie, 2010).

sít'. NetLogo má ovšem svá omezení, neumožňuje například využívat specifických knihoven operačního systému. Ovšem i tato omezení je možno principiálně odstranit. NetLogo je programováno v JAVĚ a je možno ho rozšiřovat pomocí v JAVĚ napsaných modulů. Díky tomu, že je NetLogo napsáno v Javě, je možno modely spouštět i v prohlížečích internetových stránek.

NetLogo obsahuje řadu pomocných nástrojů (např. editor tvarů agentů). Nejdůležitějším pomocným nástrojem je však nástroj „Behavior Space“ pro automatizované spouštění běhů programu. V tomto nástroji je možno definovat jakým způsobem se budou měnit počáteční parametry modelu, kolikrát bude model spuštěn pro každou kombinaci parametrů, zda se budou data ukládat při každém kroku modelu nebo až na konci atd. Výstupy z modelů je možno ukládat do tabulky v externím souboru, kterou je pak možno zpracovat programem pro statistickou analýzu dat.

Nevýhodou NetLoga je zhruba trojnásobně nižší rychlost oproti např. REPASTu, což se projeví zejména u modelů s velkým množstvím agentů a interakcí mezi nimi.




Obr. 14. – Vývojové prostředí NetLogo. Vlevo: Komunikační rozhraní. Vpravo: Na pozadí je editor programového kódu, v popředí je okno s nastavením nástroje BehaviorSpace pro automatizované spouštění modelů.

```

; setup the initial agent and its properties
to setup
  ca                                ;clear all
  crt 1                             ;creates one intial agent
  [
    set color 62                    ; sets the parameters of
    setxy 0 -50                     ; the initial agent
    set heading 0
    pd                               ; sets the pen down
  ]
end

; this|main procedure is repeatedly iterated
to go
  ask turtles                        ; all agents will draw a
  [                                  ; new branch
    fd 50 / ( ticks + 1)           ; steps forward
    hatch 1 [ rt (- random 90) ]   ; creates two new agents
    hatch 1 [ rt ( random 90) ]    ; with random heading
    die                             ; discards this agent
  ]
  tick                               ; increments the counter
end

```



Obr. 15. – Příklad efektivního programování v NetLogu – model růstu stromu. Struktura vpravo byla vygenerována po deseti iteracích.

3. Multiagentní a analytické modely v ekonomii

Multiagentní modely v ekonomii (Agent-based computational economy, ACE) dnes představují rozvíjející se alternativu k běžným ekonomickým modelům, které jsou založeny na ekonometrii nebo operačním výzkumu.

Nejblíže mají mutiagentní modely k simulacím, které jsou používány pro řešení problémů, které jsou příliš složité pro analytický způsob vyjádření a řešení (Fiala, Dlouhý, 2006). Podle velmi obecné definice je simulace spuštění modelu systému s vhodnými vstupy a zaznamenávání odpovídajících výstupů (Bratley et. al., 1987). V tomto smyslu je spuštění multiagentního modelu simulací. Existuje však i podstatně užší definice simulace tradičně používaná v operačním výzkumu. Podle Axtella (1999a) má smysl mluvit o simulaci pouze v případě, že je systém stochastický a dokážeme zformulovat rovnice vyjadřující jeho dynamiku a charakterizovat prostor řešení. Simulace potom spočívá v generování náhodných veličin, které jsou vstupem systému, a výsledný výstup slouží ke zmapování možného chování systému. Dobrým příkladem simulace je například metoda Monte-Carlo. ACE modely mohou být využity i jako takovýto typ simulace, jejich možnosti jsou však mnohem obecnější. Například to, že mohou vznikat noví agenti se zcela novým typem chování, může znesnadnit či znemožnit předem charakterizovat prostor řešení. V této práci jsem se proto přidržel Axtelovy úzké definice simulace a považuji multiagentní modely za obecnější metodu modelování systémů.

Multiagentní modely jsou častým doplňkem či alternativou k metodám operačního výzkumu. Jde zejména o metody týkající se vytváření front, managementu zásob a logistiky a analýzu interakcí v síťových strukturách. Často jsou multiagentní modely využívány ke zkoumání dynamiky systémů, které je možno popsat v jazyce teorie her. V těchto případech jsou multiagentní modely užitečné zejména pokud jsou hry opakované, hraje je větší množství agentů a neexistují Nashova ekvilibria, nebo tato ekvilibria nemusí vést při opakovaných sehrávkách k optimálnímu výsledku. Jiné metody operačního výzkumu jako je matematické programování, vícekriteriální rozhodování a další metody operačního výzkumu, které usilují o optimalizaci jednorázových rozhodnutí, je často zbytečné nebo nesmyslné nahrazovat multiagentními modely. Na druhé straně mohou složitější deliberativní agenti využívat tyto (a jakékoliv jiné formalizovatelné) metody pro své rozhodování.

Ekonometrické metody se mohou uplatnit zejména při kalibraci multiagentních modelů, když hledáme na základě empirických dat konkrétní hodnoty parametrů modelu.

Největší prostor je však v ACE v současnosti věnován vztahu mezi multiagentními modely a ekonomickým mainstreamem - neoklasickými analytickými modely.

Analytické modely představují soustavy diferenciálních či diferenčních rovnic, řešením jsou rovnovážné body ve stavovém prostoru. V neoklasických analytických modelech CGE (Computable General Equilibria) představují proměnné agregátní veličiny (nabídka, poptávka, velikost populace, HDP apod.), které charakterizují systém jako celek (top-down). V současné době nabývají na

popularitě modely DSGE (Dynamic Stochastic Genereal Equilibria), které mají s ACE některé shodné rysy: snahu odvozovat agregátní veličiny z interakcí základních prvků systému a možnost stochastických změn v systémech. Navzdory tomu považují rozdíly mezi ACE a analytickými modely za zásadní. Nejdůležitějším rozdílem je to, že analytické modely stanovují omezující předpoklady, které umožňují vypočítat rovnovážné stavy. V ACE modelech nelze výsledek vývoje systému předvídat. Dynamika systému je zkoumána v diskrétních časových krocích iterací rekurentních funkcí určujících chování agentů. To umožňuje řadu omezujících a nerealistických předpokladů opustit.

- V analytických modelech jsou agenti homogenní: mají shodné parametry a cílové funkce. V ACE mohou být agenti heterogenní: jejich chování může být ovlivněno různými typy chování v různé míře, přičemž parametry modifikující tyto typy chování mohou mít u každého agenta jinou hodnotu.
- V analytických modelech se některé globální vlastnosti systému (např. tržní ceny) vytvářejí centrálně nějakým skrytým mechanismem (např. Walrasův aukcionář). V ACE modelech mohou agenti interagovat přímo mezi sebou, všechny globální vlastnosti systému jsou důsledkem interakcí mezi agenty. Interakce mezi agenty mohou být navíc strukturovány v různých typech prostředí, jako jsou prostorové mřížky nebo sociální sítě.
- Analytické modely předpokládají existenci rovnovážných stavů, které jsou zaručeny prostřednictvím negativních zpětných vazeb (např. předpoklady klesajících výnosů). V ACE modelech systém nemusí dospět k žádné rovnováze (možné pozitivní zpětné vazby) nebo může mít rovnovážných stavů více.

Nevýhodou multiagentních modelů je nutnost zjišťovat robustnost modelu jeho opakovaným spouštěním a statistickou analýzou výsledků.

Axtell (1999a) popisuje a na příkladech ilustruje několik možných typů vztahu multiagentního modelu k analytickému modelu.

V případě, že systém je možno popsat a řešit analytickým modelem, je multiagentní model v podstatě jen pomůckou pro názornější prezentaci výsledků. To může být užitečné, třeba když vysvětlujeme dopady nějakého opatření politikům, úředníkům či firemním manažerům, kteří nejsou odborníky v oblasti, které se model týká.

Pokud jsou rovnice řešitelné numericky a jedná se o stochastický systém může být multiagentní model použit jako statistická metoda Monte-Carlo. Příkladem může být simulace vytváření front u přepážek. Úředníkovi u přepážky trvá konstantní dobu, než odbaví jeden požadavek. Zkoumáme maximální délku front, jaká se vytvoří, když budou v náhodných intervalech přicházet agenti - zákazníci. Podle Axtella je pouze v těchto případech možno označit multiagentní modely jako simulaci.

Zajímavější situace nastává, když je teoreticky dokázáno, že systém má rovnovážné stavy, ale neexistuje algoritmus, který by je dokázal efektivně najít. To je příklad modelů trhu, které předpokládají, že tržní cenu určuje centrální aukcionář. Multiagentní modely trhu, ve kterém spolu agenti interagují přímo, ukázaly, že systém rovnováhy dosáhne, přičemž počet nutných interakcí roste lineárně s počtem agentů a kvadraticky s počtem druhů zboží (Axtell, 2000).

Multiagentní modely mohou také ověřit, zda klasické teorie jsou dostatečně robustní a jestli chování systému zůstane stejné, i když některé ze silných předpokladů klasického modelu opustíme. Zde se projevuje největší výhoda multiagentních modelů. Je možno specifikovat individuální vlastnosti agentů a definovat libovolnou strukturu interakcí mezi agenty od pravidelných prostorových mřížek, kde agenti reagují pouze lokálně, přes různé typy síťových struktur až po různé druhy nepřímé komunikace prostřednictvím prostředí. Existuje řada modelů zkoumajících interakce agentů v sociálních sítích. Většinou jde o šíření nějakého názoru nebo typu chování, např. šíření nových výrobků (tzv. virový marketing), technologických inovací, politických názorů, kriminálního chování atd.

Podle Tesfatsion (2005) je možná nejdůležitější otázkou související se vztahem multiagentních modelů a analytických modelů to, jak se liší interakce agentů s omezenou racionalitou a kognitivními schopnostmi od agentů s vysokou mírou optimalizující racionality, kterou předpokládá ekonomie hlavního proudu.

Příkladem může být multiagentní model finančního trhu v této práci, nebo jiný model finančního trhu, který byl vytvořen v SantaFe institute (Arthur et. al., 1997). V tomto modelu dochází k vývoji a vzájemné kompetici mezi různými omezeně racionálními strategiemi obchodování, výsledkem je vznik tzv. technického obchodování, které není motivováno reálnými hodnotami obchodovaných aktiv (ve formě dividend), ale spekulací o pohybu cen na základě minulého vývoje systému. Technické obchodování může působit jako sebenaplnující proroctví – může způsobit změnu trhu na základě rozhodnutí založených na spekulacích o těchto změnách.

V některých případech může systém na dlouhou dobu uváznout v omezené oblasti stavového prostoru, která se podobá rovnovážnému stavu, ze kterého se však po nějaké době přemístí do oblasti jiné a teprve po dlouhé době konečně dokonverguje do rovnovážného bodu. V jiných případech může systém začít trvale oscilovat, aniž by kdy dosáhl rovnovážného bodu. V těchto případech mohou multiagentní modely významně objasnit strukturu stavového prostoru, dynamiku systému, závislost vývoje systému na počátečních parametrech apod.

Příkladem je model formování pracovních skupin. Agenti spojení ve skupině mají větší výkon než je součet jejich oddělených výkonů. Zisk se rozděluje ve skupině rovným dílem. Je tedy výhodné se sdružovat do skupin. Někteří agenti však mohou začít odvádět menší výkon než ostatní a přitom pobírají stejný podíl na zisku jako ostatní – stávají se černými pasažéry. Skupiny tedy nejdříve rostou a po nějaké době se stávají obětí černých pasažérů. Tento proces se neustále opakuje. Rovnováha skupin v tomto modelu neexistuje. Existuje však rovnováha distribuce velikostí skupin, která je podobná jako empiricky zjištěná distribuce velikostí reálných firem v USA (Axtell, 1999b).

ACE také snadno modeluje různé institucionální normy jako například legislativní omezení a vliv stochastických procesů např. exogenních „šoků“, jako je technologický pokrok nebo fluktuace cen ropy.

Závěrem můžeme shrnout, že použití multiagentních model je vhodné zejména:

1. Když chceme induktivně vysvětlit chování nějakého systému, které není analyticky popsatelné soustavou matematických rovnic. Tato nemožnost popisu plyne většinou z kvalitativní povahy systému (jako je například interakce v nějakém typu sítě nebo nespojitě přechody). K vyjádření dynamiky systému pak musíme využít alogoritmicky definované funkce.
2. Když hledáme optimální nebo suboptimální řešení nebo podmínky vedoucí k rovnovážnému stavu, ale analytické řešení je příliš složité či nemožné.
3. Nejde nám o nalezení optimálního řešení či rovnovážného stavu, ale o detailní zmapování dynamiky systému.

Tyto situace nastávají často u systémů, kde agenti a jejich interakce mají následující vlastnosti:

- chování a interakce agentů je složité, nelineární nebo nespojité.
- populace agentů je různorodá.
- při interakci mezi agenty hraje roli prostorová či sociální struktura.

ACE může být jak doplňkem analytických modelů (např. při testech robustnosti předpokladů analytických modelů) tak i zcela nezávislou výzkumnou metodou.

4. Metodologický rozbor modelu evoluce etnocentricity

4.1. Etnocentricita

Výše uvedené metodologické otázky budeme nyní ilustrovat na modelu evoluce etnocentrického chování navrženého Hammondem a Axelrodem (2003). Axelrodova práce byla vždy motivována modelováním konfliktů na mezinárodní i lokální úrovni. Axelrodovi články z osmdesátých let o evoluci kooperace (Axelrod, 1987) jsou jedny z nejcitovanějších článků v oblasti multiagentních modelů a teorie her.

Axelrod se zabýval opakovanými sehračkami věžňova dilematu. Věžňovo dilema v teorii her je situace, kdy dva hráči řeší, zda budou kooperovat či nikoliv. Mohou nastat tři základní případy. V prvním jeden z hráčů kooperuje a druhý nikoliv, pak získává nekooperující agent nejvyšší odměnu A a kooperující agent nejnižší odměnu D. Pokud oba kooperují získávají odměnu B. Pokud oba nekooperují získávají nižší odměnu C. Výše odměn musí splňovat nerovnost: $A > B > C > D$. Optimální strategií při jednom opakování hry je nekooperovat, neboť tato strategie dominuje ostatní možnosti – ať už bude druhý hráč kooperovat či nikoliv, výsledek je při nekooperativní strategii lepší než pro kooperativní.

Axelrod ukázal, jak se u society agentů, kteří disponují minimální pamětí, může při opakovaném sehrávání her typu věžňovo dilema spontánně vyvinout kooperativní herní strategie. Konkrétně pokud si agenti pamatují, alespoň jeden tah do minulosti a nevědí, kolik kol budou hrát, ukazuje se jako nejefektivnější tzv. strategie „tit-for-tat“, která oplácí kooperaci kooperací a nekooperaci nekooperací. Tento směr výzkumu se ukázal nesmírně plodný, inspiroval řadu následovníků a podrobně je zdokumentován v (Hoffman, 2000).

Na modelu, který popisujeme v této kapitole, se autorům podařilo ukázat, že i v případě, že agenti nedisponují žádnou pamětí, se může prosadit specifický druh kooperativní strategie - etnocentricita.

Etnocentricita je druh podmíněné kooperace, resp. způsob chování, při kterém příslušník nějaké skupiny – etnika má tendenci preferovat kooperaci s příslušníky svého etnika a nekooperovat s příslušníky jiných etnik. Etnocentricita je velmi rozšířený způsob chování, který vzniká již při velmi subtilních odlišnostech mezi skupinami. Empirické výzkumy ukazují, že vzniká dokonce i v případě, kdy je kooperace drahá, tj. stojí agenta nějaké zdroje. Je silnější, pokud je etnikum vystaveno nebezpečí, musí soutěžit o vzácné zdroje nebo jsou spolu skupiny v blízkém prostorovém kontaktu. Empirický výzkum též ukázal, že ochota kooperovat se svým etnikem a neochota kooperovat s cizím etnikem jsou dva různé procesy, proto je nutno je při modelování oddělovat. Axelrod a Hammond ukázali, jak se etnocentrické chování šíří a udržuje při široké škále různých podmínek, a to i v případě, že agenti nedisponují žádnou pamětí – nepamatují si, kteří agenti s nimi v minulém kole kooperovali a kteří nikoliv

4.2. Popis modelu

Model evoluce etnocentricity je modifikací klasického iterovaného věžňova dilematu. Agenti jsou rozmístěni na dvourozměrné mřížce 50x50, (v závorce budu uvádět hodnoty pro základní nastavení modelu), na jedné pozici může být vždy pouze jeden agent. Agenti jsou rozděleni do několika (4) etnických skupin, skupiny jsou reprezentovány celým číslem, graficky pak barvou. Každý agent má schopnost rozpoznat, zda sousední agent je příslušníkem vlastního, nebo cizího etnika. Agenti se mohou s jistou pravděpodobností v každém kole nepohlavně reprodukovat a přenášejí na své potomky příslušnost k etnické skupině a strategie chování. Všechny tyto znaky mohou s jistou nízkou pravděpodobností mutovat (5%). Potomek může být umístěn pouze na volné sousední pole agenta. Interakce mezi agenty jsou lokální a stejně tak je lokální i kompetice mezi agenty o vzácné zdroje - prostor pro nového potomka. Další vzácný zdroj (např. potrava apod.) ovlivňuje schopnost reprodukce. Míra v jaké s tímto zdrojem agent disponuje je vyjádřena jednoduše jako pravděpodobnost, že se agent bude reprodukovat. Zvýšení či snížení této pravděpodobnosti je důsledkem zisku či ztráty při sehrávce věžňova dilematu. To sehraávají agenti v každém kole se svými bezprostředními sousedy (v osmi okolních polích, tzv. Moorovo okolí). Každý agent získává při „narození“ základní pravděpodobnost reprodukce (12%). Pokud agent kooperuje s jinými agenty, znamená to pro něj jisté zmenšení této pravděpodobnosti, cena kooperace. Naopak, pokud jiný agent kooperuje s ním, získává násobek ceny kooperace (cena kooperace 1%, zisk z kooperace 3%). Skupina vzájemně kooperujících agentů vzájemně svoji schopnost reprodukce posiluje. Nekooperující agent nic neztrácí a může pouze získat, pokud s ním sousední agenty kooperují. Na druhé straně, pokud spolu sousedí několik nekooperujících agentů, pravděpodobnost jejich reprodukce se nijak nezvyšuje.

Agenti nemají paměť a jejich chování tudíž nezávisí na minulém chování jejich sousedů.

Formálně můžeme stav agenta i v čase t vyjádřit:

$$a_{i,t} = (e_i, s_i, r_{i,t})$$

Zde e_i je etnická příslušnost agenta a s_i je jeho strategie. Tyto dva parametry se v průběhu života agenta nemění. Paramter $r_{i,t}$ označuje pravděpodobnost reprodukce agenta v čase t .

Funkce určující chování agenta i je:

$$f_i(a_{i,t-1}, a_{j,t-1} \in N(a_{i,t-1})) = [a_{i,t}, B(a_i, t)]$$

Zde $N(a_{i,t-1})$ označuje sousedy agenta i v čase $t-1$ a $B(a_i, t)$ označuje množinu jeho potomků vytvořených v čase t (v tomto modelu může být tato množina prázdná nebo mít jeden prvek).

Strategie chování je reprezentovaná pouze dvěma binárními hodnotami kooperuje/nekooperuje s vlastními agenty a kooperuje/nekooperuje s cizími agenty.

Existují tedy čtyři možné strategie, jak se agent může chovat:

1. Kooperuje se všemi agenty (altruistická strategie)
2. Kooperuje s vlastními a nekooperuje s cizími (etnocentrická strategie)
3. Nekooperuje s vlastními agenty a kooperuje s cizími (zrádčovská strategie)
4. Nekooperuje se žádnými agenty (egoistická strategie)

Na začátku běhu modelu jsou strategie náhodně rozděleny.


Průběh každého kola sestává ze čtyř fází:

1. Imigrace: Na náhodné místo mřížky je vložen agent s náhodnými parametry.
2. Interakce: Agenti hrají se svými sousedy a zvyšuje nebo snižuje se pravděpodobnost jejich reprodukce.
3. Reprodukce: S pravděpodobností získanou na základě interakcí proběhne reprodukce agentů.

4. Úmrtí: S jistou stabilní pravděpodobností (10%) agent „zemře“, tj. je odstraněn z mřížky a uvolní se tak jeho místo.

4.3. Výsledky

Minimální kognitivní schopnosti agentů, zejména absence paměti, vylučují reciprocitu, budování reputace a podobné mechanismy, které v jiných modelech iterovaného věžňova dilematu vedou k rozšíření kooperativní strategie. I přesto se v modelu po několika stovkách kol rozšíří etnocentrická kooperativní strategie. Konkrétně podle (Hammond a Axelrod, 2003) mělo průměrně 76% agentů po 2000 kolech etnocentrickou strategii. (Jedná se o průměr z deseti různých běhů modelu a z posledních sto kol) Celkově 90% procent všech interakcí uvnitř etnik bylo kooperativních, 84% interakcí mezi etniky bylo nekooperativních.



Obr. 2. Vývoj modelu evoluce etnocentricity.

Na Obr. 2. vidíme vývoj modelu. Různé barvy na mřížce značí agenty různých etnik. Kulaté symboly značí agenty, kteří kooperují se svým etnikem, hranaté nekooperují se svým etnikem. Plné symboly kooperují s cizím etnikem, prázdné symboly nekooperují s cizím etnikem. Agent s etnocentrickou strategií je tedy značen kulatým prázdným symbolem.

Vlevo vidíme stav na začátku běhu modelu – agenti mají náhodně přidělenou etnickou příslušnost a strategii. Uprostřed vidíme typický stav po několika stovkách kol – tvoří se shluky agentů stejného etnika, převládající strategie je etnocentrická. Vpravo je graf vývoje frekvence strategií - po několika stech kolek je nefrekventovanější etnocentrická (CD – Cooperate Defect), poté altruistická (CC – Cooperate Cooperate), egoistická (DD – Defect Defect) a konečně strategie kooperující s cizím a nekooperující se svým etnikem (DC – Defect Cooperate). Pozor, barvy křivek v pravém grafu nemají souvislost s barvou etnik.

4.4. Analýza modelu

4.4.1. Cíle, základní charakteristiky a logika modelu

Model evoluce etnocentricity je typickým výzkumným modelem, který je maximálně jednoduchý a poskytuje vhled do fundamentálních zákonitostí dynamiky vývoje strategického chování ve společenských skupinách. Přes jednoduchost modelu je možno uvažovat o tom, že může být časem upraven a zpřesněn, aby předpovídal vývoj chování u reálných populací.

Základní prostorové prvky jsou políčka dvourozměrné prostorové mřížky, na kterých může být právě jeden agent. Jeden krok v modelu nemá přesně specifikovanou dobu. Jistou představu nám může dát pravděpodobnost smrti agenta - 0.1 v každém kroku. To znamená, že více než polovina agentů

nepřežije déle než sedm kroků¹⁸. Kdybychom to vztáhli k lidské populaci v primitivních podmínkách mohli bychom tedy jeden krok modelu interpretovat jako období cca 5 let.

Z extenzivního hlediska tvoří model agenti různých etnik a strategií, v modelu nejsou žádné jiné typy agentů (např. zvířata apod.) nebo jiných vlivů (např. různě úrodná půda). Z intenzivního hlediska má každý agent jen informace o svém etniku a strategii.

Agenti jsou reaktivní (nemají paměť, tj. ani schopnost se učit), interagují spolu přímo (tj. nikoliv přes prostředí) a lokálně. Mohou se rozmnožovat a umírat, díky mutacím a selekčnímu tlaku (soupeří o vzácné zdroje – prostor a pravděpodobnost rozmnožení) dochází k evoluci.

Z hlediska logického usuzování jde o model, který na základě známých faktů o existenci etnocentrického chování, napomáhá induktivnímu hledání obecných pravidel (lokalita reprodukce a interakcí) a abduktivnímu hledání základních parametrů (cena kooperace, zisk z kooperace, rychlost imigrace apod.), které vedou k evoluci etnocentrického chování.

4.4.2. Interpretace modelu

Když jsme identifikovali základní charakteristiky modelu, můžeme s využitím (Hammond a Axelrod, 2003) podrobně analyzovat mechanismus vzniku a rozšíření etnocentrické strategie. V průběhu modelu se v důsledku lokálního rozmnožování začnou z původně náhodně rozmístěných agentů tvořit shluky agentů stejného etnika. Kooperující agenti díky vzájemnému zvyšování pravděpodobnosti rozmnožení rostou rychleji. Dokud jsou shluky menší a nedotýkají se, rostou stejně rychle altruističtí i etnocentričtí agenti. Ve chvíli, kdy se shluky dotknou a začíná kompetice o volné místo pro nové agenty, začne se projevovat výhoda etnocentrických agentů. Etnocentrický agent získává podporu od etnocentrických sousedů ze svého etnika, ale nekooperuje (tudíž nesnižuje svoji fitness) s jinými etniky. Dominuje tak agenty cizích etnik s altruistickou strategií (protože ta snižuje fitness kooperací s cizími etniky), ale i s egoistickou strategií (protože ta nezvyšuje fitness vzájemnou kooperací). Důležitým efektem tohoto faktu je eliminace tzv. černých pasažérů, tj. egoistických příslušníků nějakého etnika – pokud jsou uvnitř shluku svého etnika, nemohou se rozmnožovat, protože okolo nich je málo volného prostoru. Pokud jsou na okraji shluku, je jejich rozmnožení potlačeno působením cizích etnik s etnocentrickou strategií.

Vznik a rozšíření etnocentrické strategie je robustní. Převládne u více než dvou třetin agentů i při zdvojnásobení či naopak dvojnásobném snížení hodnot řady parametrů ze základního modelu. Jde o parametry jako je cena kooperace, velikost mřížky, počet skupin, rychlost imigrace, velikost mutace nebo délka běhu modelu. Etnocentrická strategie se vyvine (díky imigraci a mutaci), i když záměrně v počáteční fázi nevygenerujeme jediného agenta s touto strategií. Evoluce etnocentrické strategie je robustní i vůči náhodným chybám, které agenti mohou dělat při rozpoznávání, zda jejich soused přísluší do jejich etnika či nikoliv (při 10% chybě převládne etnocentrická strategie u více než dvou třetin agentů). Pokud však schopnost rozlišovat mezi etniky klesne pod jistou mez, přestává být etnocentrická strategie dominantní.

Evoluce etnocentrické strategie je podmíněna lokální reprodukcí a interakcí mezi agenty. Ta zajišťuje, že většina interakcí se odehrává ve shlucích mezi agenty stejného etnika. Pokud by nový potomek byl umísťován na libovolné místo na mřížce nebo si agenti vybírali k interakci náhodného partnera odkudkoliv z mřížky, etnocentrická strategie by nebyla dominantní, převládala by spíše egoistická.

4.4.3. Vztah k analytickým modelům

Přestože strategie chování agentů jsou relativně jednoduché, jejich interakce jsou komplexní, zejména díky neustále se měnícímu sousedství mezi agenty, řadě zpětných vazeb a nespojitému charakteru mutací. Populace agentů je různorodá – existují různá etnika a strategie. Při vývoji modelu

¹⁸

$0.9^7 = 0,478$

hraje zásadní roli lokalita reprodukce a interakcí na dvourozměrné mřížce, díky které vznikají shluky agentů stejného etnika.

Tyto faktory indikují, že je obtížné sestavit analytický model schopný najít rovnovážné stavy systému, tj. nějaké stabilní distribuce strategií. I kdybychom však takový model sestavili, neilustroval by dynamiku vývoje systému – mechanismus rozšíření etnocentrické strategie. Těžko bychom také získali vhled do mechanismu eliminace černých pasažérů apod.

4.4.4. Nástroje

Původní Axelrodův model byl implementován v JAVě s použitím knihoven pro multiagentní modelování ASCAPE (2010). Zde pracuji s reimplementací původního modelu (Wilensky, 2003a), která je realizována v systému NetLogo.

4.4.5. Komplexita a samoorganizace

V důsledku lokální interakce a reprodukce vznikají shluky agentů stejného etnika. Na okrajích těchto shluků dochází ke kompetici o omezené zdroje, zejména o volný prostor pro nové potomky. Při této kompetici se jako nejúspěšnější ukazuje etnocentrická strategie. Ta zajišťuje, že shluk agentů s touto strategií má nejvyšší šanci udržet svoji integritu a rozšiřovat se. Shluky agentů stejného etnika s etnocentrickou strategií můžeme považovat za samoorganizované society, metaagenty. Můžeme předpokládat, že etnocentrické strategie budou utvářet shluky s vyšší komplexitou než jiné strategie.

Sledování vývoje komplexity v modelu evoluce etnocentricity nebylo součástí původního modelu publikovaného Axelrodem a Hammondem a je originálním přínosem této práce. Model Etnocentricity se zabudovaným sledováním komplexity je na DVD příloze této práce.

Jednou z možností jak formálně vyjádřit míru samoorganizace těchto shluků, je sledovat růst strukturální komplexity v modelu. Tu můžeme měřit jako vzájemnou informaci mezi částmi shluků a jejich okolím. Vzájemná informace mezi dvěma veličinami X a Y je dána vzorcem:

$$MI = H(X) + H(Y) - H(X,Y)$$

MI je vzájemná informace (Mutual Information), $H(X)$ je Shannonova entropie sledované veličiny u jednotlivých agentů, $H(Y)$ je entropie sledované veličiny u okolních agentů a $H(X,Y)$ je společná entropie obou veličin. Vzájemná informace je vhodnou mírou komplexity, protože je nízká jak pro zcela nepravidelné systémy, tak pro příliš pravidelné systémy. Např. model naplněný náhodně vygenerovanými agenty i model prázdný či naplněný agenty stejného druhu má nízkou vzájemnou informaci. Vysokou komplexitu mají naopak systémy, ve kterých je mnoho různých typů pravidelností, což je právě případ shluků utvořených etniky s různou strategií.

Měřil jsem tři různé typy strukturální komplexity:

- Komplexitu etnik: vzájemná informace mezi etnikem agenta a etnikem agentů v jeho okolí¹⁹.
- Komplexita strategií: vzájemná informace mezi strategií agenta a strategií agentů jeho okolí.
- Komplexita počtů stejných agentů: vzájemná informace mezi počtem shodných agentů (se stejným etnikem i strategií) v blízkém okolí agenta (okolní 4 pole – tzv. von Neumanovo okolí) a ve vzdálenějším okolí (do vzdálenosti 3 pole od agenta).

¹⁹

Za okolí budeme považovat osm okolních polí (tzv. Moorovo okolí). Hodnotou veličiny, která nese informaci o vlastnostech okolních agentů je vektor, jehož složkami jsou počty agentů s jistou hodnotou sledované vlastnosti. Např. pokud sledujeme příslušnost k etniku, tak takovou hodnotou může být vektor (2,4,0,1), který nese informaci, že v okolí daného agenta jsou dva agenty modré, čtyři agenty žluté barvy, žádný červený agent, a jeden zelený agent. Jelikož polí v okolí je osm, znamená to, že jedno pole je prázdné.

Vývoj komplexity v modelu etnocentricity vidíme na obrázku 3. vlevo dole.

Nejprve jsou všechny tři typy komplexity nízké, neboť agenti mají na začátku náhodně přidělené vlastnosti. Postupně komplexita roste, dochází k samoorganizaci shluků agentů. Posléze komplexita strategií klesá, neboť se dominantní stává pouze jediná – etnocentrická strategie a z hlediska strategií se tak systém stává mnohem pravidelnější. Naopak různorodost etnických shluků se udržuje, a proto komplexita etnické příslušnosti zůstává stabilní. Stabilní zůstává i komplexita počtu stejných agentů.


Zajímalo mne, jakým způsobem se projeví na komplexitě náhlá změna v poměru nákladů a zisků z kooperace. Prvních 5000 kol byl zisk z kooperace třikrát vyšší než náklady na kooperaci. Převládla etnocentrická strategie a vytvořily se rozsáhlé kompaktní etnické shluky. Pak byl skokově změněn zisk z kooperace na stejnou hodnotu jako náklady na kooperaci. Po dalších 5000 kolech převládla egoistická strategie a vytvořily se méně kompaktní shluky.

Změna poměru zisku a nákladů kooperace změnila nejen frekvenci jednotlivých strategií, ale ovlivnila i sledované typy strukturální komplexity.

Komplexita strategií začala růst, protože v modelu přestala převládat jen jedna – etnocentrická strategie, ale po jisté době převládla strategie egoistická a komplexita strategií opět klesla.

Komplexita etnik i komplexita počtů stejných agentů poklesla. Domnívám se, že důvodem je nižší integrita shluků egoistických agentů. Etnocentrickí agenti uvnitř shluků mají vyšší fitness než agenti na okrajích shluků (protože mají více kooperujících sousedů). Pokud se tedy uvnitř shluku uvolní místo díky smrti agenta, etnocentrickí agenti zaplní takové místo rychleji než místa na okrajích shluků. Díky tomu budou mít etnocentrické shluky nižší tendenci se rozpadat či „třepit“.

K získání tohoto výsledku bylo nutno upravit parametry původní modelu. V původním modelu mohl agent v každém kole zemřít s relativně vysokou pravděpodobností 0,1. Díky tomu byly utvořené shluky velmi malé a nestabilní a nebylo možno rozlišit strukturální komplexitu shluků etnocentrických a egoistických agentů. Snížil jsem pravděpodobnost úmrtí na 0.01 a vykompenzoval ji snížením počáteční pravděpodobnosti reprodukce z 0.12 na 0.02. Díky tomu se shluky stabilizovaly a zvětšily a rozdíly strukturální komplexity bylo možno zachytit.



Obr. 3. Nahoře vlevo: Převládá etnocentrická strategie. Nahoře vpravo: Převládá egoistická strategie. Dole vlevo: Vývoj tří typů complexity systému (v bitech). Černá vertikála označuje, kdy došlo ke změně poměru zisku a nákladů kooperace. Modrá křivka ukazuje strukturální komplexitu etnické příslušnosti, červená komplexitu strategií a zelená komplexitu počtů stejných agentů v různé vzdálenosti od agenta. Dole vpravo: Vývoj frekvencí různých strategií.

Část II:

Aplikace multiagentních modelů

5. Model transakčních nákladů na finančních trzích

Effectively working engine must have its screws tighten. But not too much.

Anonymous

5.1. Úvod

5.1.1. Stabilita finančních trhů

Tato kapitola popisuje multiagentní model vlivu transakčních nákladů na finanční trhy. Transakční náklady na finančních trzích tvoří zejména náklady na získání a interpretaci informací, čas nutný k rozhodování nebo různé typy poplatků. Transakční náklady bývají chápány jako negativní jevy, existují však případy, kdy zvýšení transakčních nákladů může být chápáno pozitivně a může přispět ke stabilitě trhu. Takovou regulační funkci mohou plnit zejména poplatky např. ve formě daní. V první polovině sedmdesátých předložil laureát Nobelovy ceny za ekonomii James Tobin návrh regulace měnových trhů. Tobin navrhoval, že veškeré krátkodobé transakce by měly být zdaněny nízkou fixní sazbou (později byl tento návrh označen jako tzv. Tobinova daň²⁰). Výsledkem by podle Tobina mělo být zamezení krátkodobým spekulacím s měnou a stabilizace trhu. Spekulace s měnou mohou vést k náhlému stažení měny z oběhu za účelem umělého zvýšení její ceny. Důsledkem pro hospodářství zemí, které měnu používají, může být dočasné snížení likvidity, problémy se získáváním úvěrů a další jevy, které mohou vést ke snížení růstu či dokonce recesi.

Tobinova daň nebyla nikdy realizována. Avšak deregulace trhů a globalizace v 90. letech a zejména pak finanční krize, která začala v letech 2007-2008, přinesla novou vlnu zájmu o Tobinovu daň. Řada ekonomů mimo hlavní proud ekonomického myšlení navrhuje její zavedení nejen kvůli stabilizaci trhu, ale také kvůli možnosti investovat její potenciálně obrovské výnosy do rozvojové pomoci, financování OSN a dalších sociálně prospěšných projektů (viz např. Penttinen et al., 2005). Proti zavedení Tobinovi daně však existuje řada argumentů. Jednak by bylo velmi obtížné ji zavést, neboť by musela být zavedena synchronizovaně na celém světě, protože jinak by se trh přemístil na nezdaněné burzy. Dalším argumentem je snížení objemu obchodů. Konečně někteří autoři uvádějí, že finanční spekulanti, jejichž aktivitu by daň podstatně zredukovala, odvádějí i užitečnou práci, neboť vyhledávají perspektivní trhy k investování apod. Objevují se též názory, že problémy se stabilitou je vhodnější řešit zlepšením makroekonomické politiky centrálních bank.

²⁰

Původní návrh byl kolem 1%, později byly návrhy redukovány až na 0.005 procenta. Při současném objemu světového měnového obchodu ve výši stovek bilionů dolarů by výnosy byly stále obrovské.

Výše uvedené námitky proti Tobinově dani považuji za relevantní (zejména první z nich). Díky současné krizi však sílí tlak na nějakou formu regulace finančních trhů. Můžeme se pokusit ukázat, jaké důsledky by regulace např. ve formě daně mohla mít. Ale model, který zde popisuji, však nemusíme nutně interpretovat jako model zavedení daní, ale obecně jako model vlivu transakčních nákladů na trh. Model bude natolik jednoduchý a všeobecný, že nebude specifický pro trh měn, ale dá se chápat jako obecný model burzy aktiv. Cílem modelu je zkoumání závislosti stability trhu, objemu obchodu a efektivity trhu na míře transakčních nákladů.

5.1.2. Chování trhů a multiagentní modely

Chování reálných finančních trhů vykazuje podstatné odchylky od tzv. Hypotézy efektivního trhu (Effective Market Hypothesis), která tvrdí, že tržní cena reflektuje veškerou informaci o reálné hodnotě obchodovaných aktiv²¹ a neměla by se od ní odchýlovat. Ve skutečnosti se tržní cena často od reálné hodnoty aktiv odlišuje, což se projevuje zejména při tzv. tržních bublinách, tedy při umělém nadhodnocení aktiv v důsledku nadměrné poptávky, či naopak při tržním krachu, tedy v důsledku nadměrné nabídky aktiv. EMH stojí podle (Schleifer, 2000) na třech základních předpokladech:

1. Investoři dokážou ohodnocovat aktiva s neomezenou racionalitou.
2. Pokud někteří investoři nejsou racionální, jejich nákupy jsou náhodné, a proto se navzájem vyruší.
3. Vliv iracionálních investorů na cenu aktiv je eliminován racionálními makléři.

Model vychází z modelu finančního trhu (Goncalves, 2003)²², který, jako řada podobných modelů, vystihuje některé typické charakteristiky reálného trhu. Na rozdíl od předpokladů EMH, platí v tomto modelu že:

1. Agenti jsou pouze omezeně racionální, tj. nemají k dispozici veškeré informace o vývoji trhu nebo je nedokážou správně interpretovat (informace jsou zašuměné).
2. Agenti jsou heterogenní, tj. reagují s různou citlivostí na zprávy o vývoji trhu a vyskytují se u nich různě silné náhodné faktory, které ovlivňují jejich rozhodnutí.
3. Agenti se rozhodují i na základě názorů svých blízkých kolegů (tato blízkost je určována na základě nějaké existující sociální či prostorové struktury).
4. Systém často nemá stabilní rovnovážné body, ale jeho stav může přecházet, často velmi náhle, mezi několika dočasně stabilními „atraktory“ stavového prostoru. V případě finančního trhu takové „atraktory“ představují jak trh bez větších výkyvů nabídky nad poptávkou, tak i bubliny a krachy.

5.2. Popis modelu

5.2.1. Původní model a jeho modifikace

Původní model přijímá řadu zjednodušení. Agenti, kteří představují účastníky trhu s akciemi, musí v každém diskrétním časovém kroku buď prodávat, nebo nakupovat fixní a pro všechny stejný objem aktiv. Časový krok nemá v modelu konkrétní reálnou interpretaci, vzhledem k dynamice

²¹ Reálná hodnota vyjadřuje čistý výnos, jaký může z aktiva plynout v budoucnosti. K jeho určení je nutno mít informace o ekonomickém subjektu, který výnos bude poskytovat. Pokud jde např. o trh s akciemi, reálnou hodnotu akcie můžeme určit, jen pokud máme podrobné informace o současném stavu a budoucích plánech firmy, která akcie vydala.

²² Goncalvesův model, který je základem modelu popisovaného v tomto článku, byl implementován v systému NetLogo. Citace odkazuje na model, který je spustitelný v internetovém prohlížeči, schopném spouštět Javovské aplety. Model obsahuje teoretický rozbor chování finančních trhů, podrobný popis jednotlivých komponent modelu a ovládání modelu.

modelu se může jednat o dobu od několika dní do několika měsíců. Obchoduje se pouze s jedním aktivem, ale můžeme si představit, že toto aktivum představuje portfolium více aktiv. Agenti nemají finanční omezení, a proto také nezanikají (nebankrotují) ani nevznikají – to ale můžeme interpretovat tak, že pokud nějaký agent zbankrotuje, je okamžitě nahrazen jiným. Agenti jsou čistě reaktivní a nedochází u nich k evoluci nových strategií jako např. v (Arthur et. al., 1997).

Na trhu se střetávají agenti různých typů²³. Jednak jsou to agenti, které mají přístup k přesným informacím o stavu ekonomického systému a řídí se jen podle nich (tzv. fundamentalists). Takto by se měli chovat agenti založení na předpokladech EMH. Dále jsou to agenti sledující trendy trhu (tzv. trend followers), kteří např. nakupují, pokud se v minulém kroku cena aktiv zvyšovala a prodávají, pokud se v minulém kroku cena snižovala. Konečně uvažujeme i agenty, kteří kupují a prodávají z hlediska trhu zcela náhodně (tzv. noise traders)²⁴. Goncalvesův model má tu výhodu, že agenti nemají přidělený specifický typ, ale spojují výše uvedené typy dohromady a zároveň se od sebe liší specifickými parametry, které určují citlivost na různé typy faktorů ovlivňujících jejich rozhodování. Rozhodnutí, zda bude agent prodávat nebo kupovat, závisí na třech faktorech:

- Zprávy o stavu ekonomiky. Zprávy jsou modelovány náhodnou veličinou s normálním rozdělením $N(0,1)$. Pokud je tato veličina větší než nula, znamená to, že je výhodné nakupovat, a veličina Q_t nesoucí informaci o kvalitativním významu zpráv v čase t nabývá hodnoty 1. V ostatních případech je výhodné prodávat a veličina Q_t nabývá hodnotu -1.
- Součet názorů blízkých kolegů $NS_{i,t-1}$ v minulém kroku. Přijímáme zjednodušující předpoklad, že agenti jsou uspořádáni v dvourozměrné mřížce²⁵. V tomto modelu byla velikost mřížky 101x101, tj. cca 10^4 agentů) Blízcí kolegové jsou ti, kteří tvoří agentovo von Neumannovo okolí (tj. čtyři okolní agenti).
- Náhodný faktor $e_{i,t}$ specifický pro každého agenta. Tento faktor je modelován náhodným rozdělením $N(\mu, \tau)$, jehož parametry je možno nastavit.

Součet vlivů, které na agenta i působí v čase t , je dán rovnicí:

$$S_{i,t} = K_i * NS_{i,t-1} + ns_i * Q_t + e_{i,t}$$

- ns_i označuje citlivost agenta na význam zpráv. Na začátku běhu modelu jsou pro každého agenta specificky generována ns_i v rozmezí 0 až báze citlivosti na zprávy (nastavitelný parametr modelu). Nižší citlivost vlastně simuluje omezenou racionalitu agentů. Fundamentalisté - agenti založené na předpokladech EMH by měli všichni tuto citlivost rovnou jedné a rozhodovali by se pouze na základě zpráv.
- K_i označuje citlivost agenta k názoru blízkých kolegů. Na začátku běhu modelu je specificky pro každého agenta vygenerována základní citlivosti v rozmezí 0 až báze citlivosti na názory kolegů (nastavitelný parametr modelu). Aktuální citlivost je dána součtem základní citlivosti a aktuální modifikace citlivosti založené na předchozím vývoji trhu. Pokud v minulém kroku trh svým pohybem potvrdil zprávy o stavu ekonomiky, citlivost se zvýší o absolutní velikost normalizovaných zisků či ztrát (které jsou mírou výhodnosti nákupu či prodeje).

²³ Zde popisují pouze nejjednodušší reaktivní typy agentů. Mohou existovat samozřejmě agenti disponující pamětí, schopní komplexnější analýzy dynamiky trhu. Agenti mohou například „chápat“ trh jako minority game a snažit se najít optimální strategii prodeje a nákupu.

²⁴ Samozřejmě z hlediska agenta nákup či prodej může být opodstatněný – agent např. potřebuje nutně peníze na opravu porouchaného automobilu, a proto prodá akcie. Z hlediska trhu je to však náhodná aktivita, neboť nijak neodráží informace o vývoji trhu.

²⁵ Chování modifikovaného Goncalvesova modelu, kde místo v mřížce agenti interagují v různých typech sociálních sítí, zkoumal Popadinec (2009). Jeho výzkum ukázal, že nestabilita trhu roste se zkracující se průměrnou nejkratší cestou mezi agenty.

Jak tento mechanismus funguje? Předpokládejme, že na trhu převládají kupující a přicházejí dobré zprávy, to vede ke zvýšené citlivosti na názory kolegů a následně pak k davovému chování (herding), které dále zvyšuje počet nakupujících (vzniká bublina). V případě, že nyní přijde špatná zpráva, citlivost k názorům kolegů se sníží, chování přestane být davové, dojde velmi rychle k desynchronizaci trhu a návratu k normálnímu režimu, počet kupujících a prodávajících se zhruba vyrovná. Opačný mechanismus funguje v případě převládajících prodávajících a špatných zpráv, v důsledku davového chování následuje krach a následně normalizace trhu.


- Všimněme si, že veškeré parametry s indexem i jsou specifické pro konkrétní agenty, tj. agenti jsou heterogenní.

Jelikož agenti nemají jiný parametr než rozhodnutí, zda budou prodávat nebo kupovat, je toto rozhodnutí formálně totožné se stavem agenta $a_{i,t}$.

Rozhodování agenta, závisí na tom, zda je součet vlivů $S_{i,t}$ kladný či záporný. Pokud je $S_{i,t}$ kladné, bude agent nakupovat, pokud záporné, bude prodávat. Funkci určující stav agenta můžeme tedy vyjádřit:

$$f_i = \text{sign}(S_{i,t})$$

V každém kroku je spočten součet všech stavů agentů $a_{i,t}$, který vydělíme počtem všech agentů. Výsledek je číslo v intervalu $<0;1>$ představující normalizovaný rozdíl mezi poptávkou a nabídkou. Změna ceny obchodovaných aktiv je funkcí tohoto rozdílu a za jistých předpokladů (viz např. Sornette, 2003, str. 49) můžeme tento rozdíl chápat jako logaritmus změny ceny aktiv tj. logaritmus míry zisků a ztrát (returns). Pokud poptávka převažuje nad nabídkou (returns je vyšší než 0), ceny aktiv a tím i zisky rostou. A naopak.



Obr. 1. Nahoře: průběh hodnoty zisků a ztrát v průběhu několika tisíc kroků v původním Goncalvesově modelu s originálním nastavením (báze citlivosti na zprávy = 0.20, báze citlivosti na názory kolegů = 0.25, $\tau = 0,9$). Náhlé výkyvy vzhůru indikují bubliny, výkyvy dolů indikují krachy. Dole vlevo: mřížka s agenty, zelení agenti nakupují aktiva, červení prodávají, trh je v normálním

režimu, většina prodávajících najde nakupující, zisky a ztráty nejsou příliš velké, cena se příliš nemění.
Dole vpravo: vysoce synchronizovaný trh, většina agentů prodává akcie, trh zažívá krach.

Původní model vykazoval pro jisté parametry bubliny a krachy velmi podobné reálným trhům. Nebyl jsem však spokojen s mechanismem modifikace citlivosti k názorům kolegů K_i . V původním modelu se K_i zvyšovala, pokud zprávy byly potvrzeny chováním trhu. To však znamenalo, že se K_i zvyšovala i u těch agentů, jejichž kolegové předvíдали pohyb trhu chybně (i když takových agentů musela nutně být menšina). To je nerealistické. Modifikoval jsem proto původní model tak, že K_i se zvyšuje, pokud názor kolegů byl v minulém kroku ve shodě s vývojem trhu. Tím ale přestalo docházet při bublinách či krachu k rozsáhlé desynchronizaci trhu při zprávách, které nebyly potvrzeny vývojem trhu. Tuto roli však mohou plnit i náhodně vzniklé série zpráv (tj. nestačí jen jedna), které nejsou ve shodě s vývojem trhu. Bylo však nutno najít nové parametry, při kterých se model choval realisticky – tj. podobně jako trh reálný. Dále byla na polovinu snížena hodnota sumy názorů blízkých kolegů (zabránilo se tím, aby model trvale uvíznul v bublinách či krachu.)

5.2.2. Model s transakčními náklady

Důsledky zvýšení transakčních nákladů (Transaction Costs, TC) se projeví sníženou ochotou agentů účastnit se tržních transakcí. Tento jev můžeme snadno napodobit tak, že zavedeme do modelu nový parametr TC a agent bude obchodovat pouze v případě, že:

$$\text{abs}(S_{i,t}) > \text{TC}$$

Pokud agent obchodovat nebude, potom bude jeho stav nastaven na hodnotu 0. Formálně můžeme funkci určující chování agenta vyjádřit:

$$f_i = \begin{cases} \text{sign}(S_{i,t}) ; & \text{pokud } \text{abs}(S_{i,t}) > \text{TC} \\ 0 ; & \text{pokud } \text{abs}(S_{i,t}) \leq \text{TC} \end{cases}$$

Transakční náklady můžeme tedy interpretovat tak, že jde o hranici, která určuje, jak velký musí být vliv faktorů ovlivňujících rozhodování agenta, aby agent začal obchodovat.

Velikost transakčních nákladů je v tomto modelu čistě abstraktní veličina, kterou je obtížné interpretovat jako nějakou reálnou např. peněžní hodnotu. Samotná hodnota transakčních nákladů není tak zajímavá jako reakce modelu na změny této veličiny.

Transakční náklady jsou v modelu faktorem, který ovlivňuje všechny účastníky trhu ve stejné míře (což by platilo zejména v případě zavedení daní). V realitě však mohou existovat pro různé agenty různé transakční náklady jiných typů než daně – např. náklady na získání informací apod.

Zvýšení TC má tři následky:

- **Snížení nestability trhu** – zvýšení TC povede ke snižování směrodatné odchylky zisků a ztrát, kterou můžeme považovat za míru nestability trhu. Díky vyšší hodnotě TC se totiž větší počet agentů zdržuje nákupu či prodeje, a tudíž neposiluje davové chování svých sousedů. Trh má díky tomu menší tendenci přecházet do atraktorů bublin a krachů, a pokud se tak stane, uvízne v nich kratší dobu. Snižování nestability trhu je pozitivním důsledkem TC.
- **Snížení objemu obchodu** (Volume of Trade, VT) – menší počet agentů bude jak prodávat, tak nakupovat. Toto snížení objemu obchodu, které se dá interpretovat i jako snížení množství informace o chování okolních agentů, které mají agenti k dispozici. Snižuje se množství informace, která prochází trhem. Tato informace ovšem není totožná s kvalitativním významem zpráv, ale je zkreslena vlivem davového chování a náhodných faktorů. Snížení množství této informace tak může mít do jisté míry i pozitivní vliv na efektivitu trhu.

- **Změny neefektivit trhu**, kterou můžeme chápat jako podíl agentů, kteří obchodují v rozporu s kvalitativním významem zpráv (Tj. prodávají, když $Q(t) = 1$ a naopak). Říkejme těmto agentům chybující agenti. Jejich podíl poroste, když vliv davového chování a náhodného faktoru bude opačný než kvalitativní význam zpráv. To se týká zejména situací, kdy trh „uvízne“ v dlouhotrvající bublině či krachu. Neefektivitu jsem měřil třemi způsoby, které jsou nejnadhěji interpretovatelné:

1. $abs (VT(t) * Q(t) - returns(t)) / 2$
 - o Tj. podíl chybujících agentů²⁶.
2. $abs (VT(t) * Q(t) - returns(t)) / (2 * VT(t))$
 - o Tj. podíl chybujících agentů relativně k počtu agentů, kteří se obchodu účastnili²⁷. Eliminujeme tedy vliv změn objemu obchodu.
3. $abs (Q(t) - returns(t)) / 2$
 - o Tento vzorec můžeme interpretovat tak, že zahrnuje do míry neefektivit nejen počet chybujících agentů, ale i snížení objemu ochodu. Agent, který se obchodu neúčastnil, zvyšuje výsledek o jednu polovinu svého podílu. Chybující agent zvyšuje výsledek o jeden podíl (viz pozn. 25). Neúčast tedy zvyšuje neefektivitu o polovinu méně než chybné obchodování. Z výsledku není možné přesně zjistit, kolik agentů se obchodování neúčastnilo a kolik chybovalo. Tuto informaci je ovšem možno případně snadno vyčíst z hodnot VT.

Cílem modelu je zkoumání vlivu změn TC na tyto tři charakteristiky: stabilitu trhu (kterou budeme měřit jako rozptyl zisků a ztrát), objem obchodu a efektivitu trhu.

5.3. Výsledky experimentů

Experimenty byly prováděny s následujícími parametry modelu:

- Počet agentů = 10201 (mřížka 101 x 101 agentů)
- Počet časových kroků pro každou hodnotu TC = 3000
- Báze citlivosti na zprávy = 1
- Báze citlivosti na názor kolegů = 1
- Báze náhodného faktoru rozhodování $N(0, 0.5)$
- Proměnlivým parametrem byla míra TC, která se pohybovala v intervalu $<1.0; 1.3>$.


Na obrázku 2 vidíme hodnoty zisků a ztrát (returns) v průběhu 3000 kroků pro hodnoty $TC \in \{1.0; 1.15; 1.25; 1.30\}$. Vidíme, že pro nízké hodnoty $TC=1.0$ představují atraktory trhu pouze bubliny a krachy, přičemž trh v nich může setrvat relativně dlouhou dobu. Při vyšší úrovni $TC=1.15$ se objevuje další atraktor, kterým je normální režim, při kterém jsou počty nakupujících a prodávajících agentů zhruba v rovnováze a zisky a ztráty fluktuují kolem 0. Při ještě vyšším $TC=1.25$ dochází k bublinám i krachům jen zřídka, průběh zisků a ztrát je podobný datům z původního modelu s originálními parametry – viz Obr. 1. Další zvýšení $TC=1.30$ vede k eliminaci bublin a krachů.

²⁶

Proměnné VT a returns jsou normované na celkový počet agentů. Výraz tedy určuje podíl chybujících agentů na celkovém počtu agentů. Dvojka je ve jmenovateli proto, že každý chybující agent zvyšuje čitatele o dvojnásobek normovaného podílu jednoho agenta – tj. $1/10201$. Výraz může v modelu nabývat hodnot $<0; 1>$.

²⁷

Ze statistického zpracování bylo vyloučeno několik málo případů, kdy byla hodnota VT(t) nulová.



Obr. 2. Vývoj zisků ztrát pro různé hodnoty TC. Odshora dolů $TC \in \{1.0; 1.15; 1.25; 1.30\}$.

Na obr. 3. vidíme výsledky experimentu. Na osách x všech grafů je míra TC z intervalu $<1.0; 1.3>$ s krokem 0.01. Pro každou hodnotu TC běžel model tři tisíce kol. Na grafech vidíme průměrné hodnoty, nebo směrodatné odchylky z dat vygenerovaných v průběhu modelu.²⁸

Horní graf zobrazuje vývoj směrodatné odchylky zisků a ztrát (returns) a objemu obchodu. TC zapříčiňuje snižování jak odchylky, tak i objemu obchodu. Odchylka zisků a ztrát je mírou nestability trhu, čím je odchylka nižší, tím méně trh kolísá, tím méně se objevují dlouhá uvíznutí trhu v bublině či krachu. V bublině i v krachu prodává či nakupuje většina agentů, proto objem obchodu tak úzce souvisí s odchylkou. Důležitým zjištěním je, že objem obchodu neklesá rychleji než odchylka zisků a ztrát.

Na prostředním grafu je zobrazen vývoj minima a maxima zisků a ztrát. Minima mohou nabývat hodnoty -1, což je extrémní krach, kdy všichni agenti prodávají. Maxima mohou nabývat hodnoty 1, což je extrémní bublina, kdy všichni agenti nakupují. Až do hodnoty $TC=1.27$ docházelo při běhu modelu k výskytu extrémních bublin a krachů. Důležité zjištění je, že malé zvýšení TC (které

²⁸

Nepouštěl jsem model opakovaně pro různé hodnoty TC. Vzhledem k charakteru modelu je téměř ekvivalentní pustit model jednou po dobu 3000 kroků a 30-krát po dobu 100 kroků. Navíc, na začátku jsou názory agentů generované náhodně a v několika počátečních krocích se model „stabilizuje“. Při jednom dlouhém spuštění je z hlediska celkového počtu kroků tato počáteční fáze zanedbatelná

je, jak vidíme na horním grafu, doprovázené jen malým snížením objemu obchodu) může vést k eliminaci extrémních bublin a krachů, resp. ke značnému snížení minim a maxim zisků a ztrát (zvýšení TC z 1.26 na 1.3, vedlo ke snížení minim a maxim téměř na polovinu).


Spodní grafy ukazují průběh tří výše popsaných typů neefektivity trhu. Na grafech jsou průměrné míry neefektivity, chybové sloupce vymezují 95% intervaly spolehlivosti.

Levý graf zobrazuje podíl chybujících agentů, tj. agentů, kteří obchodovali v rozporu s kvalitativním významem zpráv. Zatímco pro nízké TC chybovala až třetina agentů, se zvyšujícím se TC klesá tento počet k nule. K tomu ovšem přispívá i snižující se objem obchodu.

Prostřední graf je velmi podobný, ale zcela eliminuje vliv klesajícího objemu obchodu. Zobrazuje podíl chybujících agentů relativně vzhledem k počtu agentů, kteří se obchodu účastnili. Vidíme, že tato hodnota klesá s rostoucím TC k nule. To můžeme interpretovat tak, že i když z horního grafu vidíme, že objem obchodu klesá, podíl chybujících agentů klesá ještě rychleji. Pro hodnoty TC vyšší než 1.27 je tento podíl téměř nulový, přičemž objem obchodu dosahuje hodnot těsně pod 0.2 (tj. obchoduje necelých 20% z celkového počtu agentů).

Domnívám se, že příčinou snižujícího se počtu chybujících agentů při zvyšujícím se TC je snižování vlivu davového chování a náhodných faktorů. Davové chování se snižuje, protože agenti s nulovým $S_i(t)$ izolují prodávající či kupující agenty a zabraňují jejich komunikaci. Vliv náhodného faktoru se snižuje, protože se zvyšujícím se TC se snižuje pravděpodobnost, že náhodný faktor zkreslí zprávy natolik, že agent udělá chybu.

Pravý graf zobrazuje míru neefektivity, která kombinuje vliv podílu chybujících agentů a snižujícího se objemu obchodu (tj. zvyšujícího se počtu agentů, kteří neobchodují). Každý chybující agent zvyšuje tuto míru neefektivity o jeden podíl (viz pozn. 25) a neobchodující agent ji zvyšuje o polovinu podílu. Vývoj této míry je nemonotónní, s rostoucím TC nejprve klesá, poté roste. Rozpětí hodnot, ve kterých se tato míra pohybuje, je podstatně menší než předchozí dvě míry, tomu odpovídají i opticky širší intervaly spolehlivosti v grafu, ovšem je zřetelné, že průběh křivky je zachycen s dostatečnou statistickou spolehlivostí. Tento výsledek můžeme interpretovat tak, že zpočátku vede zvýšení TC ke snížení počtu chybujících agentů, které bude více než kompenzovat snížení objemu obchodu (tj. zvýšení počtu neobchodujících agentů). Konkrétně pokud se zvýší počet neobchodujících agentů o dva, sníží se v průměru počet chybujících agentů o více než jedna. Se zvyšujícím se TC se vliv snižování počtu chybujících agentů a zvyšování počtu neobchodujících agentů vyrovnává. A od jisté hodnoty začne převažovat vliv zvyšujícího se počtu neobchodujících agentů. Konkrétně pokud se zvýší počet neobchodujících agentů o dva, sníží se v průměru počet chybujících agentů o méně než jedna.



Obr. 3. Výsledky experimentu. Na ose x všech grafů jsou hodnoty TC z intervalu $\langle 1.0; 1.3 \rangle$ s krokem 0.1. Na horním grafu vidíme průběh směrodatné odchylky zisků a ztrát a průměrný objemu obchodu. Na prostředním grafu je zobrazen průběh minima a maxima zisků a ztrát (returns). Spodní tři grafy ukazují různé míry efektivitu trhu.

5.4. Závěr

Tento model je extrémně zjednodušený a není kalibrován na žádná empirická data. Výsledky experimentů proto nemůžeme formulovat přímo jako doporučení činitelům, kteří obchodují na finančním trhu, nebo se zabývají jeho regulací. Na druhé straně můžeme výsledky experimentů chápat jako pokus o zmapování možných důsledků změn transakčních nákladů.

Snížení nestability trhu je doprovázeno stejně rychle se snižujícím objemem obchodu. Snižující se objem obchodu jsme v modelu chápali jako negativní jev. To ovšem nemusí platit vždy. Je pravděpodobné, že jistá část čistě spekulativního objemu obchodu není žádoucí a bylo by možno ji odstranit zvýšením transakčních nákladů. Teprve když by transakční náklady převýšily nějakou kritickou hranici, začal by se snižovat i žádoucí objem obchodu.

Institute, které by usilovaly o velmi vysokou stabilitu trhu bez rizika extrémních bublin a krachů, mohou využít výsledky týkající se minima a maxima zisků a ztrát. Ty napovídají, že existuje kritická hodnota transakčních nákladů, po jejímž překročení přechází trh do stabilnější fáze. Tento přechod se přitom téměř nedotkne objemu obchodu. Objem obchodu však bude v této fázi relativně nízký oproti trhu s nízkými transakčními náklady.

Při hodnocení vlivu transakčních nákladů na efektivitu trhu hraje důležitou roli objem obchodu. Institute, která by chtěla zvýšit efektivitu trhu, aniž by pro ni byl objem obchodu prioritou, by mohla zvýšením transakčních nákladů snížit počet chybujících agentů téměř na nulu, přičemž by objem obchodu sice podstatně klesl, avšak nesnížil by se až na nulu (v tomto modelu by klesl objem obchodu na zhruba pětinu maximálního objemu).

Institute, která by zahrnula do míry neefektivity i snižování objem obchodu, může předpokládat, že pro jistou hodnotu transakčních nákladů dosahuje neefektivita minima. V tomto bodě se vyrovnává pozitivní vliv snižujícího se počtu chybujících agentů a negativní vliv snižujícího se objemu obchodu (zvyšujícího se počtu neobchodujících agentů). To ostatně naznačuje i motto této kapitoly o správně utažených šroubech.

Transakční náklady snižují počet chybujících agentů, neboť ruší vliv davového chování a náhodných faktorů. Při vyšších hodnotách TC se bude stále silněji projevovat vliv zpráv a obchodovat budou jen ti agenti, kteří jsou na jejich kvalitativní význam nejcitlivější. Tato situace je nejpodobnější původním předpokladům EMH – fundamentalističtí agenti se racionálně řídí podle zpráv. Je zajímavé, že by k takovému stavu mohla vést vyšší míra regulace trhu – jako jedna z forem transakčních nákladů.

Také můžeme předpokládat, že účastníky trhu při vysokých transakčních nákladech nebudou menší spekulanti ani drobní investoři, ale spíše velké finanční instituce. Pokud se totiž někdo pustí do obchodování při vysoké úrovni transakčních nákladů, musí k tomu mít významný důvod, nestačí jen lehká fluktuace v předpokládaném zisku. Tyto instituce mají většinou nejlepší přístup k informacím a jsou proto nejcitlivější na kvalitativní význam zpráv.

6. Model evoluce averze k riziku a nejistotě

6.1. Úvod

6.1.1. Hypotéza očekávaného užitku a averze k riziku a nejistotě

Model popsaný v této kapitole se snaží ukázat jednoduchý způsob, který mohl vést k evoluci rozhodovacích mechanismů, které se u lidí projevují jako averze k riziku a nejistotě. Důležitou inspirací pro tento model byly poznatky experimentální ekonomie a neurověd, které ukázaly neudržitelnost tzv. Hypotézy očekávaného užitku (Expected Utility Hypothesis, EUH) a nutnost nalézt komplexnější popis lidského rozhodování v situacích rizika nejistoty.

Při popisu chování agenta, kterému chybí informace o výsledku jeho rozhodnutí, můžeme rozlišit dva typy situací. V situaci rizika má agent k dispozici informace o pravděpodobnostním rozložení možných výsledků rozhodnutí. V situaci nejistoty (ambiguity) mu tyto informace chybí. Uveďme příklad: Agent vybírá náhodně kuličky ze sáčku, přičemž ví, jaké typy (např. barvy) kuliček jsou v sáčku. Úkolem agenta je vsadit na jistý typ kuliček. Pokud tento typ bude vybrán, agent získá odměnu (např. peněží). V situaci rizika má agent informace o počtu jednotlivých typů kuliček. V situaci nejistoty tuto informaci nemá.

Klasická ekonomická teorie popisuje chování agenta pomocí Hypotézy očekávaného užitku. Podle této hypotézy je agent schopen přiřadit každé odměně nějaký subjektivní užitek. Výši tohoto užitku²⁹ určuje užitková funkce U . Hypotéza očekávaného užitku předpokládá, že agent je plně racionální a rozhodne se pro takovou variantu, od které očekává, že mu v budoucnu přinese největší užitek. Očekávaný užitek EU nějakého rozhodnutí je dán sumou součinů pravděpodobností jednotlivých výsledků p_i a užitkové funkce příslušných odměn.

$$EU = \sum_i p_i U(\text{odměna}_i)$$

Např. pokud je v sáčku dohromady sto kuliček a z toho 30 červených a pokud je odměna za správnou sázku 100\$, pak je očekávaný užitek sázky na červenou kuličku:

$$EU = 0.3U(100\$) + 0.7U(0\$)$$

²⁹

Kardinalistický přístup chápe užitek jako kvantifikovatelnou hodnotu. Ordinalistický přístup užitek přímo nekvantifikuje, ale předpokládá, že užitky z různých odměn je možno poměřovat a uspořádat. Jak uvidíme dále, v případě Allaisova problému a Ellsbergova paradoxu vystačíme s ordinalistickým přístupem.

Pokud je agent v situaci nejistoty a nemá informace o pravděpodobnosti jednotlivých možných výsledků rozhodnutí, předpokládá EUH, že agent je schopen generovat subjektivní odhady těchto pravděpodobností.

EUH předpokládá, že užitková funkce je nezávislá na pravděpodobnosti možného výsledku. Očekávaný užitek se tedy mění proporčně ke změnám pravděpodobnosti výsledků. Dalším předpokladem je nezávislost užitkové funkce na tom, zda jsou pravděpodobnosti výsledků známé (situace rizika) nebo zda jsou jen subjektivně odhadované (situace nejistoty).

Hypotéza očekávaného užitku dokázala vyřešit některé zdánlivé paradoxy ekonomického rozhodování např. tzv. Petrohradský paradox³⁰, ale v 50. a 60. letech minulého století soustředila experimentální ekonomie pozornost na příklady rozhodování, které EUH vysvětlit nedokáže. Důvodem jsou právě předpoklady nezávislosti užitkové funkce na riziku a nejistotě.

Příkladem falzifikace předpokladu nezávislosti užitkové funkce na riziku je tzv. Allaisův problém (Allais, 1953). Agent prochází dvěma experimenty, v každém má zvolit mezi dvěma typy her. Výsledky jsou určeny tabulkou 1.

Experiment 1				Experiment 2			
Hra A		Hra B		Hra C		Hra D	
Výhra	Šance	Výhra	Šance	Výhra	Šance	Výhra	Šance
\$1 milion	100%	\$1 milion	89%	0\$	89%	0\$	90%
		0\$	1%	\$1 milion	11%		
		\$5 milion	10%			\$5 milion	10%

Tab. 1. Allaisův problém

Lidé volí v prvním experimentu v průměru spíše hru A s jistou výhrou před hrou B, i když ta slibuje vysoký zisk výměnou za relativně malé riziko nulového zisku. Samotný fakt této volby není ještě sám o sobě zajímavý, dá se vysvětlit pomocí EUH – předpokládáme výrazný záporný užitek nulového zisku.

V druhém experimentu volí většina lidí hru D před hrou C. To je však v rozporu s EUH.

Průměrnou volbu v prvním experimentu můžeme podle EUH vyjádřit nerovnicí:

$$1U(\$1M) > 0.89U(\$1M) + 0.01U(0\$) + 0.1U(\$5M)$$

$$0.11U(\$1M) > 0.01U(0\$) + 0.1U(\$5M)$$

Průměrnou volbu v druhém experimentu můžeme podle EUH vyjádřit nerovnicí:

³⁰

Petrohradský paradox je založen na empirickém zjištění, že většina lidí zvolí jistotu pevné částky, překračující nějakou kritickou hodnotu, oproti možnosti hrát následující hru: V prvním kole se hodí mince, a pokud padne hlava, hráč získává 2\$, v opačném případě se hraje dál. Pokud nyní padne hlava, hráč získává 4\$. Pokud hlava padne až na n-tý pokus, hráč získává 2ⁿ\$. Očekávaná výhra je tedy 0.5x2+0.25x4+0.125x8...= 1+1+1...= ∞. Jednání agenta je tedy zdánlivě paradoxní. Hypotéza očekávaného užitku využívá empirické zjištění, že míra užitku každé další přidané jednotky odměny typicky klesá (zákon klesajícího mezního užitku). Očekávaný užitek ze hry proto může konvergovat k jisté kritické hodnotě. Pokud hráč dostane jistotu částky, jejíž užitek překračuje kritickou hodnotu, zvolí jistotu této pevné částky před hraním nejisté hry. I když by prostřednictvím hry mohl s rizikem získat částku větší.

Podotkneme však, že zákon klesajícího mezního užitku nemusí platit všeobecně pro všechny agenty a všechny typy odměn.

$$0.89U(0\$) + 0.11U(\$1M) < 0.9(0\$) + 0.1U(\$5M)$$

$$0.11U(\$1M) < 0.01U(0\$) + 0.1U(\$5M)$$

Tento spor je většinou interpretován jako falsifikace předpokladů EUH o nezávislosti užité funkce na pravděpodobnostech výsledků her alternativních³¹. EUH nepostihuje např. možnost, že negativní užitek nulového zisku je závislý na poměru rizika mezi alternativními hrami. Riziko v našem případě představuje pravděpodobnost nulového zisku. U hry B nastala kvalitativní změna v pravděpodobnosti nulového zisku oproti hře A (poměr těchto pravděpodobností je nekonečný, resp. 1% / 0%), kdežto u hry D došlo pouze k minimální změně v pravděpodobnosti nulového zisku oproti hře C (poměr těchto pravděpodobností je 90% / 89%).

Falsifikace předpokladů EUH poukazuje na existenci rozhodovacího mechanismu, který EUH nepostihuje, a který je citlivý na poměr rizika mezi alternativami (hrami). Tato citlivost se v průměru projevuje jako averze vůči alternativě, která je podstatně rizikovější než jiné dostupné alternativy.

Z hlediska subjektivního prožívání je možno vyjádřit vzájemné závislosti mezi alternativami tak, že oproti jistému zisku ze hry A, který chápeme „jakoby už byl náš“, znamená i velmi nízké riziko nulového zisku u hry B vlastně riziko značné ztráty³², a proto výrazně negativně ovlivní hodnocení této alternativy.

Vliv poměru rizika je však závislý i na výši odměny. Pro většinu lidí by znamenal zisk milionu dolarů významnou změnu v jejich životě, a proto i malé riziko ztráty vnímají výrazně negativně. Pokud by se jednalo o odměnu třeba jen v řádu desítek dolarů, mnoho lidí by toto riziko vnímalo např. jako příležitost k příjemně vzrušující sázce a preferovali by hru B před hrou A.

Příkladem falsifikace předpokladu o nezávislosti užité funkce na nejistotě je tzv. Ellsbergův paradox (Ellsberg, 1961). Podobně jako u Allaisova problému agent prochází dvěma experimenty, v každém má zvolit mezi dvěma typy her. Agent náhodně vybírá ze sáčky, o kterém má informace, že je v něm celkem 90 kuliček. 30 kuliček je červených, zbytek tvoří v neznámém poměru kuličky modré a žluté barvy. Pokud agent vybere kuličku barvy, na kterou si vsadil, vyhraje odměnu, např. 100\$. V prvním experimentu volí agent, zda vsadí na červenou nebo na modrou kuličku. Lidé v průměru volí sázku na červenou kuličku, kde je jistá pravděpodobnost výhry 1/3, oproti modré kuličce, kde je pravděpodobnost výhry nejistá a pohybuje se v rozmezí 0 - 2/3. V druhém experimentu volí agent, zda vsadí na červenou a žlutou kuličku nebo na modrou a žlutou kuličku. V tomto případě většina lidí volí sázku na modrou a žlutou kuličku, kde je opět jistá pravděpodobnost výhry 2/3, oproti alternativní hře, kde je pravděpodobnost výhry nejistá a pohybuje se mezi 1/3-1.

Průměrnou volbu v prvním experimentu vyjádříme podle EUH nerovnicí:

$$1/3U(100\$) + 2/3U(0\$) > P_m U(100\$) + (1 - P_m) U(0\$)$$

$$1/3 > P_m$$

Průměrnou volbu v druhém experimentu vyjádříme podle EUH nerovnicí:

$$1/3U(100\$) + P_z U(100\$) + P_m U(0\$) < 1/3U(0\$) + P_z U(100\$) + P_m U(100\$)$$

$$1/3 < P_m$$

³¹ Můžeme ale uvažovat i o falsifikaci dalších předpokladů EUH, např. o nezávislosti užité funkce na pravděpodobnosti jednotlivých výsledků pro danou hru. EUH nepostihuje např. možnost, že negativní užitek z nulového zisku nemusí růst přímo úměrně s jeho rostoucí pravděpodobností. Tj. např. negativní užitek 90% šance na nulový zisk nemusí být roven 90-ti násobku negativního užtku 1% šance na nulový zisk, jak předpokládá EUH. Každé další procento pravděpodobnosti nulového zisku může např. zvyšovat negativní užitek o menší díl.

³² Z ekonomického hlediska jde vlastně o tzv. náklady obětované příležitosti. Obětujeme jistý zisk ze hry A, abychom si mohli zahrát hru B. V ekonomické praxi se náklady obětované příležitosti ilustrují na příkladu, kdy se rozhodujeme mezi podnikáním s nejistým ziskem a zaměstnáním s pevnou mzdou, tedy jistým ziskem. Pokud se rozhodneme podnikat, obětujeme tomu vlastně mzdu, kterou bychom jinak získali, a musíme ji proto zahrnout do nákladů na podnikání.

P_m a P_z jsou subjektivní odhady pravděpodobnosti výběru modré a žluté kuličky.

Tento spor je většinou interpretován jako falsifikace předpokladů EUH o nezávislosti užité funkce na nejistotě. To poukazuje na existenci rozhodovacího mechanismu, který EUH nepostihuje, a který je citlivý na míru nejistoty v jednotlivých alternativních rozhodnutích. Tato citlivost se v průměru projevuje jako averze vůči alternativě, která je bližší situaci nejistoty než jiné dostupné alternativy.

6.1.2. Neuronální koreláty averze k riziku a nejistotě

Rozvoj neurověd v 90. letech minulého století, který byl umožněn zejména rozvojem metod pro snímání aktivity mozku, přinesl mnoho poznatků i o neurofyzilogických podkladech lidského rozhodování. Rozvíjí se interdisciplinární spolupráce neurověd, psychologie a ekonomie. Empirická data neurověd jsou interpretována v konceptuálním rámci, který poskytuje ekonomie a psychologie. Někteří vědci pro toto nové a perspektivní spojení disciplín navrhuji název Neuroekonomie (Glimcher & Rustichiny, 2004).

Pro averzi k riziku a nejistotě jsou relevantní zejména výsledky shrnuté v (Hsu et. al., 2006). Tento výzkum se zaměřil na sledování aktivity některých mozkových center, o kterých se vědělo již z minulých experimentů, že ovlivňují rozhodování v situacích rizika a nejistoty³³. Jedná se o oblast striata, které hraje roli v očekávání odměny, orbitofrontální kortex (OFC), jehož poškození vede ke snížené schopnosti rozhodování při nedostatku informací o výsledku, a amygdalu, která reaguje na různé typy nejednoznačných podnětů a ovlivňuje pozornost. Experimenty byly odvozeny od Ellsbergova paradoxu. Probandi se měli rozhodovat mezi hrami s různou mírou nejistoty, resp. různou mírou chybějící informace o výsledku. V první skupině byli zdraví lidé, činnost výše uvedených mozkových center byla v průběhu experimentu snímána pomocí fMRI. V této skupině experiment prokázal významnou změnu aktivity všech zkoumaných center při rozhodování v podmínkách rizika i nejistoty.

Aktivita striata se zvýšila, a to v situaci nejistoty méně než v situaci rizika. Aktivita OFC a amygdaly se také zvýšila, avšak v situacích nejistoty více než v situaci rizika.

Druhá skupina se skládala ze dvou podskupin. Tvořili ji jednak lidé s fokálními lézemi v oblasti OFC a kontrolní skupina lidí s fokálními lézemi v temporálním kortexu. Experiment ukázal, že lidé s lézemi v OFC projevují významně nižší averzi jak k riziku, tak k nejistotě než lidé z kontrolní skupiny.

Přestože autoři článku prokázali odlišnost reakcí při rozhodování v situaci rizika a v situaci nejistoty, nevyvozují, že existují dva různé mechanismy pro zpracování těchto situací. Přiklání se spíše k názoru, že existuje mechanismus jeden, který je aktivní úměrně nedostatku informací o výsledcích rozhodnutí³⁴.

Striatum se podílí na očekávání odměny, přičemž nejistota očekávanou odměnu snižuje.

OFC a amygdala se podílejí na tom, že agent věnuje rozhodování pozornost úměrně nedostatku informací. Rozhodnutí provedená na základě nedostatečných informací sebou nesou neznámé a tudíž potenciálně nebezpečné důsledky, proto musí být mobilizovány kognitivní i behaviorální zdroje k získání dodatečných informací o situaci.

³³ Tato studie nezkoumala aktivitu dalších relevantních mozkových center. Jde například o anteriorní cingulární kortex, který hraje roli při detekci a učení protichůdných a chybných reakcí, a ventromediální prefrontální kortex, který se podílí na hodnocení budoucích následků rozhodnutí (Glimcher & Rustichiny, 2004).

³⁴ Mezi situacemi rizika a nejistoty existují přechodová stadia, která se liší mírou dostupné informace. Zvyšování této informace se dá ilustrovat následujícím příkladem: Mějme sáček se 100 bílými nebo černými kuličkami. Nevíme, jaký je poměr kuliček (situace nejistoty). Úkolem je vsadit na jednu barvu. Pokud dostaneme možnost před sázkou prohlédnout n kuliček ze sáčku, budeme získávat o poměru kuliček v sáčku informaci, která bude růst s n . Pokud dostaneme možnost prohlédnout před sázkou všech sto kuliček, informace o poměru kuliček bude maximální, dostáváme se do situace rizika.

Výsledky neurofyziologických experimentů zatím napovídají, že EUH se soustředila pouze na čistě racionální rozhodování a nerozpoznala vliv emocí (ve formě averze) na naše rozhodování.

Zatím neproběhly studie, které by systematicky zkoumaly rozhodování v podmínkách rizika a nejistoty v různých kulturách. Existence mozkových center, jejichž aktivita se projevuje jako averze k riziku a nejistotě, však dává důvod k domněnce, že tato averze není jen kulturně podmíněna, ale je i výsledkem biologické evoluce. Můžeme dokonce vyslovit hypotézu, že tato averze se nevyvinula jen u člověka či u primátů, ale že k jejímu vývoji dochází u rozsáhlé třídy evolučních procesů.

6.2. Popis modelu

V této kapitole popíšeme minimální model evoluce averze k riziku a nejistotě založený na evoluční dynamice populace vzájemně interagujících a rozmnožujících se agentů. Hlavním smyslem tohoto modelu je identifikovat vzájemné vztahy klíčových parametrů, které tuto evoluci ovlivňují.

6.2.1. Averze k riziku a nejistotě

Jak jsme uvedli výše, můžeme předpokládat, že averzi k riziku i k nejistotě ovlivňuje jeden mechanismus. Vzhledem k tomu není nutné, aby agenti disponovali vnitřním modelem prostředí, který by rozlišoval mezi rizikem a nejistotou. Jedinou informací, kterou agenti o prostředí získávají, je informace zděděná od jejich rodičů. Tuto informaci je možno v našem minimálním modelu redukovat na jediný parametr, a to je averze k riziku a nejistotě (dále jen averze). Tento parametr určuje jak genotyp, tak fenotyp agenta a hraje podobnou roli jako subjektivní užitek v ekonomických experimentech. Populace agentů je heterogenní – každý agent může mít jinou averzi.

Averze představuje pravděpodobnost, že se agent rozhodne pro typ chování, ve kterém získá odměnu s jistotou, oproti riskantní alternativě, která slibuje vyšší odměnu, ovšem i možnost ztráty. Toto rozhodování mezi typy chování můžeme chápat jako rozhodování mezi dvěma typy her.

Průměrná averze v populaci agentů je závislý parametr, který v průběhu evoluce konverguje k hodnotě optimální pro dané parametry prostředí. Vzhledem k tomu, že se jedná o stochastický model, průměrná averze nekonverguje k jedné hodnotě, ale k relativně stabilnímu rozmezí hodnot.

6.2.2. Opakovaná rozhodnutí, fitness a délka života agentů

V biologické evoluci hrají významnou roli často se opakující situace, ve kterých se agent musí rozhodovat. Allaisův problém ani Ellsbergův paradox nijak nezohledňují možnost, že rozhodnutí mezi typy her se budou opakovat³⁵. Tento typ opakovaného rozhodování v podmínkách nejistoty ale dobře testuje tzv. Iowa test³⁶, při němž mají lidé s lézemi v OFC významně menší úspěšnost než zdraví lidé.

³⁵ V tomto textu rozebíráme význam opakovaných her zejména z hlediska rizika, že agent ztratí možnost hrát další hry v budoucnu a tím získávat budoucí odměnu – možnost reprodukce.

Pro evoluci averze k nejistotě mají opakované hry význam ještě v jiném smyslu. V popisovaném minimálním modelu představuje jedno reprodukční období jednu hru. Představme si složitější model, kde se agent musí v průběhu jednoho reprodukčního období mnohokrát rozhodovat mezi riskantní a nejistou hrou podobně jako v Ellsbergově paradoxu. Prohra v jednotlivých hrách nemusí mít fatální následky, ale aby agent přežil a získal nenulovou fitness, musí kumulovat dostatečnou odměnu, např. musí získat při každodenním shánění potravy dostatek zásob na zimní období. U rizikové hry dokáže agent určit, jaké má šance získat dostatečně velkou kumulovanou odměnu. Pokud je pravděpodobnost výher dost vysoká a počet her značný, blížíme se situaci, kdy je výhra jistá. U nejisté hry agent tyto možnosti nemá a nedokáže odhadnout, zda nakumuluje dostatečnou odměnu a nedojde k fatální situaci.

Při tomto typu opakovaných her s kumulovanou odměnou se tedy rozhodování mezi rizikovou a nejistou hrou blíží rozhodování mezi jistou a rizikovou hrou.

³⁶ Při Iowa testu mají probandi možnost vybírat karty z několika balíčků, přičemž některé karty přinášejí odměnu a jiné nikoliv (nebo dokonce přinášejí trest). Probandi nemají informace, v jakém poměru jsou karty jednotlivých typů namíchány v různých balíčcích. Probandi výběr opakují a postupně zjistí, u kterých balíčků je vyšší pravděpodobnost odměny. Probandi s lézemi v OFC, mají problémy přestat vybírat z balíčků s nižší pravděpodobností odměny, a to i přesto, že si tuto skutečnost uvědomují.

Můžeme tedy předpokládat, že evoluce averze k riziku a nejistotě je úzce spojena s evolucí schopností efektivně se rozhodovat v opakujících se situacích mezi hrami s odlišnou mírou informace o výsledku. Život agenta je možno schematicky popsat jako sérii období, v nichž agent musí provádět rozhodnutí. Efektivita rozhodnutí je dána dopadem na budoucí akce agenta, zejména na pravděpodobnost, že agent bude schopen úspěšné reprodukce, tj. že bude mít životaschopné a reprodukce schopné potomky. Jde o komplexní schopnost počít, porodit, postarat se o potomka a prosadit ho v konkurenci s jinými potomky při omezených zdrojích. V minimálním modelu však budeme tuto schopnost reprezentovat jediným parametrem – aktuálním fitness.

Aktuální fitness označuje schopnost agenta mít reprodukce schopné potomky v aktuálním období. Aktuální fitness je evolučním ekvivalentem odměny za výhru v ekonomických experimentech.

Nejdůležitějším volným parametrem modelu je délka života agentů L . Tu budeme pro zjednodušení chápat jako počet období, ve kterých agenti dělají rozhodnutí mezi typy chování. V každém období probíhá zároveň i reprodukce agentů - viz životní cyklus agenta.

V experimentech se délka života agentů pohybovala v intervalu $<1; 30>$ ³⁷.

6.2.3. Typy chování

Agent se na nejzákladnější úrovni musí rozhodovat mezi dvěma typy chování. První typ chování je konzervativní opakování známých vzorců, které jsou dobře prozkoumané. Agent má relativně dost informací o možných výsledcích, takže tento typ chování přináší menší riziko a nejistotu, ale agent získává jen nízkou základní fitness. Druhý typ chování je explorativní hledání nových možností, které přináší možnost zvýšit základní fitness faktorem, který nazveme výhoda vítěze. Na druhé straně však zvyšuje i pravděpodobnost, že dojde k fatální situaci, která se projeví buď dočasnou, nebo trvalou ztrátou schopnosti reprodukce.

V minimálním modelu mohou agenti zvolit mezi dvěma typy her. Buď jistotu přežití se základní fitness, nebo hru, ve které mohou sice s jistou pravděpodobností zemřít³⁸ (ztratit trvale schopnost reprodukce), ale v opačném případě se jejich aktuální fitness zvyšuje o výhodu vítěze. Pravděpodobnost smrti P_d a výhoda vítěze a představují další volné parametry modelu.

6.2.4. Populace agentů

V tomto minimálním modelu má populace agentů konstantní velikost N . Omezení velikosti populace simuluje selekční tlak v důsledku omezených zdrojů.

Velikost populace spolu s počtem paralelně se vyvíjejících populací³⁹ a počtem období, po které evoluci sledujeme⁴⁰, tvoří parametry, které mají význam pro spolehlivost statistické analýzy modelu. V experimentech byla nastavena velikost populace 250, počet populací 20 a počet období 3000.

6.2.5. Fitness a pravděpodobnost reprodukce

Základní fitness je pro všechny agenty stejná a je rovna 1. Pokud se agent rozhodne pro rizikovou hru a vyhraje, fitness se zvětší na $(1+a)$, kde a je výhoda vítěze.

³⁷ Délka života agentů samozřejmě nemusí mít žádnou horní hranici. Ovšem pro příliš vysoký počet reprodukčních období bychom těžko hledali rozumnou biologickou interpretaci. Délku jednotlivých období není možno přesně vztáhnout k reálnému časovému úseku. Avšak vzhledem k tomu, že má jít o model lidské evoluce a v modelu je nastavena maximální délka života na třicet období, jedná se o dobu zhruba jednoho až dvou let.

³⁸ Samozřejmě bychom mohli v modelu počítat jen s dočasnou ztrátou schopnosti reprodukce, která sníží aktuální fitness na několik budoucích období (to můžeme interpretovat jako zranění nebo nemoc). V tomto minimálním modelu budeme však počítat pouze s trvalou ztrátou schopnosti reprodukce, která je z hlediska modelu ekvivalentní smrti agenta.

³⁹ Výsledná průměrná averze k riziku pro každou kombinaci parametrů prostředí je počítána jako průměr z průměrů několika nezávisle se vyvíjejících populací.

⁴⁰ Tento parametr musí mít dostatečně vysokou hodnotu, aby průměrná averze k riziku měla možnost konvergovat ke stabilnímu rozmezí hodnot.

Pravděpodobnost reprodukce každého agenta je rovna podílu:

$$\text{fitness_agenta} / (\text{aktuální_počet_agentů} + a * \text{aktuální_počet_vítězů})$$

Aktuální počet agentů nemusí být shodný s maximální velikostí populace, protože v daném okamžiku mohli někteří agenti zemřít a na jejich místa teprve přijdou nově narození agenti.

6.2.6. Reprodukce

Sexuální reprodukce představuje jediný typ interakce mezi agenty. V modelu nehraje roli žádná jiná prostorová či sociální struktura. V minimálním modelu nebudeme při sexuální reprodukci rozlišovat dvě specifická pohlaví a budeme považovat agenty za hermafrodity. Při reprodukci je na základě aktuální pravděpodobnosti reprodukce vybrán jeden rodič. Dále je náhodně vybrán jiný agent, který představuje sexuálního partnera⁴¹. Potomek získá averzi, která je součtem průměru averze rodičů a náhodné hodnoty dané mutačním faktorem. Mutační faktor udává maximální rozpětí, o které se může averze k riziku u potomka zvýšit či snížit, výsledná averze však musí zůstat v intervalu $<0; 1>$. Vyšší mutační faktor vede k rychlejší konvergenci průměrné averze k riziku. Avšak příliš velký mutační faktor vede k „zašumění“ výsledků. V experimentech byl mutační faktor nastaven na hodnotu 0.1.

Pokud se agenti nereprodukují sexuálně, sexuální partner se nevybírání a potomek agenta dědí jeho averzi k riziku modifikovanou náhodnou hodnotou danou mutačním faktorem. V tomto případě je obtížné interpretovat populaci jako populaci jednoho druhu, protože agenti spolu nijak neinteragují. Modelujeme pak spíše koevoluci mnoha nezávislých druhů, kde každý agent představuje jeden druh.

6.2.7. Životní cyklus agentů

Shrňme v krátkosti životní cyklus agentů během jednoho období. Agenti se nejprve rozhodují mezi hrami a hrají. Poté jsou odstraněni agenti, kteří se rozhodli pro rizikovou hru a prohráli - zemřeli nebo jejich věk překročil maximální délku života. Nakonec proběhne reprodukce, při které je vygenerováno tolik nových agentů, kolik jich bylo odstraněno, čímž se udrží konstantní velikost populace. Tento proces je iterován, dokud není dosaženo předem nastaveného počtu období.

6.2.8. Formální popis modelu

Jelikož je stav agenta určen po celou dobu jeho života jen jediným parametrem – averzí k riziku a nejistotě (označme ji p), můžeme stav agenta i v čase t vyjádřit:

$$a_{i,t} = p_i$$

Funkce určující chování agenta i při sexuální reprodukci je:

$$f_i(a_i, a_{rnd}) = [a_i, B(a_i, t-1)]$$

Zde a_{rnd} je agent, který byl náhodně vybrán, pokud došlo k sexuální reprodukci a $B(a_i, t-1)$ označuje množinu potomků vytvořených v čase t (v tomto modelu může být tato množina prázdná, nebo mít jeden prvek).

V situaci bez sexuální reprodukce je funkce ještě jednodušší:

$$f_i(a_i) = [a_i, B(a_i, t-1)]$$

⁴¹

V popisovaném minimálním modelu se může stát, že v jednom reprodukčním období jsou vybráni několikrát ti samí agenti jako rodiče. Dokonce se může stát, že jako sexuální partner bude agentovi vybrán on sám. Při větších velikostech populace je však vliv těchto případů na celkovou dynamiku evoluce zanedbatelný.

6.3. Výsledky experimentů

V této závěrečné kapitole budeme diskutovat evoluční dynamiku minimálního modelu pro různé hodnoty klíčových parametrů prostředí.

V experimentech sledujeme, k jaké hodnotě bude konvergovat průměrná hodnota averze v průběhu evoluce dlouhé 3000 období. Experimenty probíhaly vždy pro všechny délky života agentů $L \in \langle 1; 30 \rangle$.

Grafy 1-6 dokumentují vývoj průměrné averze pro různé hodnoty L a pevně danou výhodu vítěze $a=4$ a pravděpodobnost smrti $P_d=0.1$. Grafy 7-12 jsou histogramy averze u všech agentů v populaci po 3000 obdobích. Průměrná averze je počítána jako průměr průměrných averzí z 20 nezávisle se vyvíjejících populací. Šedá oblast nad a pod křivkou průměrné averze udává minimální a maximální hodnoty v jednotlivých populacích.

Výsledky ukazují, že se zvyšující se délkou života agentů roste i hodnota, ke které konverguje průměrná averze.

Grafy 13.-14. a 15.-16. dokumentují závislost hodnoty, ke které konverguje průměrná averze, na délce života agentů pro různé kombinace hodnot výhody vítěze a pravděpodobnosti smrti. Vlevo vidíme výsledky modelu se sexuální reprodukcí a vpravo bez sexuální reprodukce. V těchto grafech označují horní a dolní meze 90% interval spolehlivosti odhadu průměrné hodnoty z 20 běhů modelu (každý běh modelu můžeme chápat jako evoluci paralelní populace).

Průměrná averze vždy roste se zvyšující se délkou života, ale růst je pomalejší pro vyšší výhodu vítěze a nižší pravděpodobnost smrti. Zvýšení výhody vítěze je možno kompenzovat zvýšením pravděpodobnosti smrti a naopak – dosáhneme velmi podobného výsledku.

Z porovnání grafů vyplývá, že sexuální reprodukce zrychluje růst averze v závislosti na délce života agentů. Při sexuální reprodukci jsou totiž partneři vybíráni náhodně. Agenti s nízkou averzí, pokud nezemrou, mají sice vyšší fitness, ale mohou si náhodně vybrat za partnera agenta s vysokou averzí. Potomek pak zdědí průměr averzí obou agentů.

Důležitým zjištěním je, že křivka závislosti průměrné averze na délce života agentů má kromě limitních případů tvar, který se podobá logistické křivce, tzv. S-křivce. Pro některé kombinace hodnot výhody vítěze a pravděpodobnosti smrti existuje kritické rozmezí délky života agentů, kdy dochází k fázovému přechodu. Pro malé zvýšení délky života dochází v tomto rozmezí ke značnému zvýšení průměrné averze.

6.3.1. Diskuse k modelu

Při prezentacích tohoto modelu jsem se setkal s řadou otázek, které bych rád vyjasnil v této kapitole.

Tento model vysvětluje velmi jednoduchým (a možná nejjednodušším možným) způsobem vliv parametrů prostředí (výhoda vítěze, pravděpodobnost smrti, maximální délka života) na dynamiku vývoje averze k riziku a nejistotě. Tento model je natolik jednoduchý, že by se mohlo zdát, že jsme z modelu dostali jen to, co jsme do něj vložili. Ale tento model nebyl vytvořen proto, abychom zjistili něco překvapivého, ale proto, aby ukázal, jak jednoduchý mechanismus může vést k evoluci averze k riziku a nejistotě. Tento model ilustruje velmi obecným způsobem, jak mohlo vzniknout chování, které pozorujeme u lidí (a možná i u jiných zvířat).

Je zřejmé, že rozhodování u lidí není možné redukovat na jeden parametr – averzi k riziku. Avšak evoluce rozhodovacích mechanismů může být řízena některými klíčovými parametry a tento model může poukázat na to, které parametry postačují k tomu, aby se takový mechanismus vyvinul. Tento model také nijak nenaznačuje, jakým způsobem budou konkrétní procesy v mozku ovlivňovat naše rozhodování. Výzkum neurofyziologických korelátů averze k riziku a nejistotě ale napovídá, že tato averze není daná pouze kulturně, ale že vznikla v průběhu evoluce. Navíc tento výzkum naznačuje, že chování v situaci rizika a nejistoty řídí jeden mechanismus (na kterém se však podílí několik mozkových center), který je citlivý na míru nejistoty. Na těchto předpokladech je založen i tento model – modelujeme evoluci jednoho mechanismu averze k riziku i nejistotě.

6.3.2. Algebraicko - numerické řešení

Na otázku, při jaké averzi bude maximalizována fitness pro různé kombinace výhody vítěze, pravděpodobnosti smrti a délky života, lze odpovědět i pomocí algebraického popisu modelu a numerického řešení.

Označme averzi p , výhodu vítěze a , pravděpodobnost smrti P_d .

Základní fitness je 1, fitness s výhodou vítěze je $1 + a$

Pravděpodobnost přežití v jednom kroku označme Q :

$$Q = p + (1-p)(1 - P_d) = 1 - P_d + P_d p$$

Pravděpodobnou fitness v jednom cyklu označme F :

$$F = p \cdot 1 + (1-p)(1 - P_d)(1+a)$$

Celková fitness za L období je tedy:

$$QF + Q^2F + \dots + Q^LF = Q [(1-Q^L)/(1-Q)] F$$

Hledat extrémy celkového fitness je problematické. Celkový fitness sice můžeme derivovat, ale vyjde velmi složitý výraz:

$$\begin{aligned} & (p + (1+a)(1-p)(1-P_d))(1-P_d+P_dp) \left(-\frac{L P_d (1-P_d+P_dp)^{-L+1}}{P_d - P_dp} - \frac{P_d (1-P_d+P_dp)^L}{(P_d - P_dp)^2} \right) + \\ & (p + (1+a)(1-p)(1-P_d)) P_d \left(1 - \frac{(1-P_d+P_dp)^L}{P_d - P_dp} \right) + (1 - (1+a)(1-P_d))(1-P_d+P_dp) \left(1 - \frac{(1-P_d+P_dp)^L}{P_d - P_dp} \right) \end{aligned}$$

Řešit rovnici, kde na jedné straně je tento výraz a na druhé nula, nezvládl žádný z matematických programů, které jsem zkoušel. Velmi výkonný program Mathematica (verze 5.2) po zadání napsal hlášení, že tuto rovnici patrně vůbec nelze algebraicky řešit.

Hledal jsem proto maximum celkového fitness pro různá p při různých kombinacích a , P_d , a L . numericky. Výsledky jsou uvedeny v grafech 17-20.

Pro srovnání s výsledky multiagentního modelu využijeme levý horní graf. Tento graf ukazuje, při kterých hodnotách averze bude mít agent maximální fitness při různých délkách života, přičemž měníme postupně hodnoty výhody vítěze $a \in \{0.5, 2, 4, 32\}$ a pravděpodobnost smrti zůstává $P_d=0.1$. To je stejná situace jako na grafech 15-16, které zachycují hodnoty, ke kterým konverguje averze v multiagentním modelu. Srovnáním grafů vidím, že numerické výsledky jsou velmi blízké modelu bez sexuální reprodukce (pozor, barvy křivek mezi sebou nekorespondují).

6.4. Závěr

Popsaný model ilustruje, že při vyšší délce života se „nevypatí“ volit riskantní či nejisté hry, i když umožňují vyšší aktuální fitness. Pokud agent prohraje a ztratí schopnost reprodukce, přichází o užitek z budoucích období, tj. přichází o možnost hrát hry a reprodukovat se v relativně vysokém počtu budoucích obdobích. Úspěšnou strategií se může stát vysoká averze k riziku, kdy má agent i při základní pravděpodobnosti reprodukce relativně vysokou šanci, že v průběhu jeho dlouhého života dojde k reprodukci. Při sexuální reprodukci je navíc tato šance zvýšena tím, že může být vybrán jako sexuální partner jiného agenta.


Při nízké délce života se „vypatí“ volit riskantní či nejisté hry umožňující vyšší fitness. Pokud agent prohraje a ztratí schopnost reprodukce, přijde díky nízké délce života v průměru jen o malý počet budoucích období, ve kterých by mohl hrát hry a reprodukovat se. Pokud tuto situaci

zobecníme, můžeme udělat následující závěr: existuje velmi jednoduchý evoluční mechanismus, který povede ke vzniku averze k riziku a nejistotě. Tato averze bude ovlivňovat chování agenta v situacích, kdy se agent může opakovaně rozhodovat a získávat odměnu a zároveň existuje šance, že díky některým z krátkodobého hlediska výhodným volbám ztratí možnost pokračovat v získávání odměny v budoucích obdobích.

Pokud připustíme, že popsaný minimální model zahrnuje prvky, které měly významný vliv i na evoluci moderního člověka, získáváme důležitou explanační pomůcku pro vysvětlení averze k riziku a nejistotě, kterou lidé projevují při ekonomickém rozhodování.

Můžeme formulovat hypotézu, že neuronální struktury, jejichž aktivita se projevuje jako averze k riziku a nejistotě, jsou citlivé na evolučně významné typy her, kdy nedostatek informací o výsledku může znamenat potenciálně fatální výsledek – trvalou ztrátu reprodukčních schopností agenta. Aktivita těchto neuronálních struktur je relativně nezávislá na čistě racionálně-matematickém vyhodnocování situace (které je patrně evolučně mnohem mladší). Proto lidé v ekonomických experimentech projevují averzi k riziku i nejistotě, i když k ní z hlediska Hypotézy očekávaného užítu zdánlivě není racionální důvod, neboť se jedná o jednorázové rozhodnutí a „nejde o život“.


Allaisův problém ale zřetelně ilustruje, jak závažné opodstatnění citlivost na riziko má. Zejména pokud je možná ztráta velmi vysoká – i když nemusí jít přímo o život, jsme vysoce citliví na rozdíl mezi hrami, kde je výsledek jistý a hrami, kde se objevuje byť malá možnost ztráty. Nejsme tolik citliví na rozdíl mezi hrami, v nichž vždy existuje nějaké riziko ztráty, ale toto riziko je mírně odlišné. Riziko nulového zisku, byť velmi nízké, oproti jisté odměně milionu dolarů, znamená kvalitativní rozdíl mezi hrami A a B. Rozdíl rizika ztráty u hry a C a D je oproti tomu subjektivně téměř nerozlišitelný. Kvalitativní rozdíl v míře rizika mezi hrami A a B způsobuje výraznou averzi k riziku, protože se nacházíme v jedinečné situaci, která může významně změnit náš život. Pokud ztratíme možnost získat milion dolarů, ztratíme tak všechnen užitek, který by nám přinesl život milionáře v budoucích obdobích. Pokud by výše nabízené odměny byla o tři řády nižší, situace by přestala být jedinečná, případná ztráta by ovlivnila naši možnost získávat odměnu v budoucích obdobích jen minimálně a averze k riziku by se díky tomu podstatně snížila.



Grafy 1-6. 3000 období dlouhý vývoj průměrné averze k riziku a nejistotě pro různé délky života agentů

($a=4$, $P_d=0.1$, $L \in \{1, 7, 13, 19, 25, 30\}$)


Grafy 7-12. Histogramy averze k riziku a nejistotě pro výše zmíněné parametry po 3000 obdobích




Graf 13-14. Závislost hodnoty, ke které konverguje průměrná averze k riziku a nejistotě, na délce života agentů, pro různé hodnoty pravděpodobnosti smrti

$P_d \in \{0.2, 0.1, 0.05, 0.025\}$; $a=1$.

Vlevo: Se sexuální reprodukcí. Vpravo: Bez sexuální reprodukce.



Grafy 15-16. Závislost hodnoty, ke které konverguje průměrná averze k riziku a nejistotě, na délce života agentů, pro různé hodnoty výhody vítěze $a \in \{0.5, 2, 4, 32\}$; $P_d=0.1$
Vlevo: Se sexuální reprodukcí. Vpravo: Bez sexuální reprodukce.



Grafy. 17-20. Numerické řešení problému, při jaké averzi k riziku a nejistotě ($\max.p$) bude maximální suma fitness při různých kombinacích délky života L , pravděpodobnosti smrti P_d a výhody vítěze a .

7. Model monopsonu na trhu práce

*V práci nám řekli, že kvůli krizi musíme pracovat delší dobu za stejnou mzdu. Musím splácet hypotéku a nemůžu si dovolit přijít o práci. Teď, když je tolik nezaměstnaných, bych jinou práci těžko sháněl.
- Jeden z českých pracovníků*

7.1. Úvod

Učebnicová mikroekonomická analýza individuální křivky nabídky práce je založená na křivkách indiference mezi dobou odpočinku a výší mzdy (viz např. Samuelson, 1991; Soukupová a kol., 2002). Tyto křivky jsou výslednicí protichůdného působení důchodového a substitučního efektu. Výsledek může být pro každé individuum velmi odlišný. Ekonomové předpokládají, že individuální nabídka práce je rostoucí – tj. roste se zvyšující se mzdou. Učebnice ale popisují i situaci, kdy zvyšování mezd nejprve vede ke zvyšování agregátní nabídky práce, ale po překročení určité úrovně mezd vydělávají pracovníci již tolik, že dojde k převaze důchodového efektu a nabídka práce se začne snižovat. Ovšem učebnice předpokládají, že agregátní nabídka práce zůstává rostoucí, protože do odvětví mohou vstupovat noví pracovníci přilákaní vysokými mzdami.

Téměř nikdo (když pomineme marxistickou ekonomii) se nevěnuje opačnému postupu – co se bude dít, když budeme mzdy dlouhodobě snižovat. Lze předpokládat, že nejdříve se bude agregátní nabídka práce se snižujícími mzdami také snižovat. Ale jak se budou mzdy blížit k existenčnímu minimu, tedy objemu prostředků, který je nutný k holému přežití, začne se agregátní nabídka práce „paradoxně“ zvyšovat. Pracovníci musí začít nabízet stále více práce, aby přežili. Dosáhnout této situace by samozřejmě bylo výhodné pro majitele podniků – získali by tím maximální množství práce za minimální ceny. V rozvinutých zemích existují dva limity takového vývoje. Jedním je minimální mzda a druhým je předpokládaná konkurence mezi zaměstnavateli. Vzájemná konkurence mezi zaměstnavateli předpokládá, že zaměstnavatelé neuzavírají nekalé dohody o výši mezd, a že pracovníci jsou dostatečně mobilní a mohou mezi zaměstnavateli volit. Minimální mzda může být v důsledku kombinace tlaku zaměstnavatelských lobby a inflace dotlačena téměř k existenčnímu minimu. Možnost pracovníků vybrat si mezi různými zaměstnavateli bývá omezená – je omezena jejich mobilita, náklady na rekvalifikaci jsou vysoké a konečně různé podniky mohou být vlastněny jednou korporací nebo kartelem, který může uplatňovat stejnou mzdovou politiku. Tyto

faktory umožňují, aby se ze zaměstnavatele stal monopson, tedy jediný nakupující na trhu práce.

V této situaci není pro pracovníky možné odcházet a hledat si práci u jiných zaměstnavatelů, a tak snižovat agregátní nabídku práce (alespoň v krátkodobém či střednědobém horizontu). Díky tomu se u monopsonu může při snižování mezd blízkých existenčnímu minimu zvyšovat agregátní nabídka práce.

7.2. Popis modelu

7.2.1. Hlavní prvky modelu

Níže popsáný multiagentní model je model monopsonu na trhu práce. Agenti představují jednotlivé pracovníky. Zaměstnavatel je specifický agent, kterého můžeme chápat jako prostředí, ve kterém pracovníci žijí. Pracovníků může být velké množství a parametry jejich chování se mohou lišit. Zaměstnavatel je pouze jeden. Pracovníci a zaměstnavatel se střetávají na trhu práce, jehož klíčovými parametry jsou mzdy a nabídka práce.

Model navíc zkoumá na mikro i makro úrovni vliv dalších faktorů, jako je výše úspor a zadlužení pracovníků a vliv spotřebních půjček.

7.2.2. Pracovníci

7.2.2.1. Individuální nabídka práce


Individuální nabídka práce je v modelu chápána jako průměrná denní práce za časovou jednotku. Maximum je 14 hodin práce denně, minimum 0. Časová jednotka odpovídá jednomu kroku modelu, což by realitě odpovídala cca jednomu měsíci až jednomu roku. Tímto způsobem můžeme zachytit to, že pracovníci nabízejí práci v odlišené struktuře. Víme, že řada pracovníků nepracuje každý den stejný počet hodin a nepracuje ve všech dnech, nebo týdnech. Průměrná denní práce 6 hodin denně tak může odpovídat pracovníkovi, který pracuje každý den v časové jednotce 6 hodin nebo pracovníkovi, který pracoval jen polovinu dní v časové jednotce 12 hodin denně.

7.2.2.2. Existenční a statusové minimum

Model předpokládá, že individuální nabídka práce je ovlivňována existenčním minimem a statusovým minimem. Existenční minimum je částka, kterou pracovník potřebuje k tomu, aby zabezpečil své základní potřeby a reprodukoval svoji pracovní sílu. Existenční minimum je stejné pro všechny pracovníky. Spotřeba nad existenční minimum umožňuje pracovníkům dosahovat sociálního statusu, proto ji nazývám statusovou spotřebou. Statusové minimum je částka, podle které se řídí užitek ze statusové spotřeby. Statusové minimum může být několikrát vyšší než je existenční minimum a pro různé pracovníky může být odlišné. V modelu je statusové minimum generováno pro každého pracovníka náhodně s normálním rozložením se středem rovným trojnásobku a směrodatnou odchylkou rovnou jednomu násobku existenčního minima (statusové minimum však nemůže být nižší než existenční).

Vztah mezi mzdou a počtem hodin práce nutným pro dosažení obou minim je daný hyperbolami:

$$\text{práce nutná k dosažení minima} = \text{existenční (statusové) minimum} / \text{hodinová mzda}$$



Graf 1. - Závislost mezi hodinovou mzdou (osa x) a individuální nabídkou práce (osa y) potřebnou k dosažení existenčního minima (fialová hyperbola) a statusového minima (modrá hyperbola). Černá křivka znázorňuje individuální nabídku práce jednoho pracovníka. Tato křivka je v modelu nespojitá, protože zvýšení nabídky práce znamená vždy jednu celou hodinu práce navíc.

Individuální nabídka práce tedy musí minimálně dosahovat takové hodnoty, aby výsledný výdělek pokryl existenční minimum. Každá další jednotka výdělku přináší užitek ze statusové spotřeby - statusový užitek. Tento užitek odpovídá substitučnímu efektu. V modelu je statusový užitek dán mocninou funkce, jejímž základem je rozdíl mezi výdělkem a statusovým minimem. Exponent této funkce je nižší než jedna, a statusový užitek tedy roste rychleji pro mzdy nižší, než je statusové minimum a pomaleji pro mzdy vyšší. Důchodovému efektu naopak odpovídá negativní užitek z času obětovaného práci⁴², který je také dán mocninou funkce, ale s exponentem vyšším než jedna, a tedy roste stále rychleji s větším množstvím práce. Pracovník bude nabízet takové množství práce, při kterém bude maximalizovat svůj celkový užitek, k čemuž dojde tehdy, když se mezní hodnoty statusového užtku a negativního užtku z času obětovaného práci budou navzájem rovnat⁴³.

7.2.2.3. Půjčky a dluhy, utrácení a spoření

Agenti - pracovníci jsou reaktivní, ale mají jakousi minimální paměť, která spočívá v tom, že si „pamatují“ jaké mají dluhy a úspory.

Každý pracovník, který není schopen v každém kroku modelu zaplatit existenční minimum, si musí na jeho zaplacení půjčit. Pracovníci se však mohou zadlužit i tím, že si vezmou spotřební půjčku. Tuto půjčku si v modelu mohou vzít jen pracovníci, kteří mají práci a nenulové úspory (tj. nejsou již v dlužích). Velikost půjčky je vždy desetinásobek existenčního minima. Pravděpodobnost, s jakou si pracovníci berou spotřební půjčky (dále jen zkráceně „pravděpodobnost půjček“), je jedním z klíčových parametrů modelu. Jedním z hlavních cílů experimentů s modelem je popsat vliv tohoto parametru na chování modelu.

⁴² Předpoklad, že odpracovaný čas znamená vždy negativní užitek je samozřejmě zjednodušující a do hlavního proudu ekonomického myšlení ho zavedly až práce neoklasických marginalistů. Institucionální a jiné alternativní ekonomické směry chápou, že práce samozřejmě může mít užitek sama o sobě jako smysluplná aktivita. To ovšem předpokládá, že na pracovišti panují odpovídající podmínky a zaměstnanec se ztotožňuje se smyslem své práce. V modelu se ovšem přidržíme zjednodušujícího pojetí, neboť modelovat užitek z práce samé by vyžadovalo velmi sofistikovaný psychologický model zaměstnance a pracovního prostředí.

⁴³ Podrobný popis tohoto mechanismu nalezne zájemce ve zdrojovém kódu modelu.

Pokud si půjčku vezme pracovník, jehož úspory jsou větší než půjčka, tak ji okamžitě splatí a jeho úspory se sníží o velikost půjčky. Je to tedy to samé, jako by si půjčku nevzal, jen se rozhodl pro drahý nákup, na který má peníze. Pokud má pracovník nižší úspory než je výše půjčky, využije je celé na pokrytí části půjčky a zbytek se stane dluhem.

Dluh splácení pracovníci v každém kole splátkou o velikosti existenčního minima. Zadlužený pracovník tak potřebuje nabízet při stejné mzdě dvakrát tolik práce, aby zaplatil existenční minimum i splátku a nezadlužil se ještě více. Zadlužení tak ovlivňuje nabídku práce. Může se stát, že při stejné mzdě může pracovník zvýšit nabídku práce, když se zadluží, a po splacení dluhu zase nabídku práce snížit. Splátky nejsou v modelu úročeny.⁴⁴

Na začátku běhu modelu získají pracovníci náhodnou výši úspor o maximální velikosti desetinásobku existenčního minima. Pokud mají pracovníci práci, získávají v každém kole celkovou mzdu rovnou součinu hodinové mzdy a jimi nabízené práce. Tuto mzdu vždy nejprve přičte k úsporám (přijde mu na účet) a následně může z úspor utrácet.

Pokud je pracovník schopen splatit životní minimum a půjčky, může část mzdy dále spotřebovat a část uspořit. Při modelování spotřeby jsem se snažil vystihnout psychologii spotřebitele. Spotřeba se řídí velikostí mzdy, úspor, tím zda má pracovník zrovna práci a velikostí statusového minima. Rozhodně nepovažuji za vhodné modelovat utrácení jedním parametrem jako například sklon ke spotřebě (resp. k úsporám). Jelikož je model spotřeby relativně komplikovaný a přitom není pro chod modelu klíčový (úspory neovlivňují nabídku práce), umístil jsem podrobný popis modelu spotřeby do poznámky pod čarou⁴⁵.

7.2.3. Zaměstnavatelé

7.2.3.1. Mzdy a zisk

Mzdy představují v modelu vždy hodinové mzdy. Mzdy mohou být buď pevně dané jako externí parametr nebo je určuje zaměstnavatel tak, aby maximalizoval zisk. Zaměstnavatel nemá žádné informace o celkovém tvaru funkce agregátní nabídky práce. Zaměstnavatel však může sledovat, jaká agregátní nabídka vzniká při jisté úrovni mezd a reagovat na ni. Mzdy jsou proto v modelu chápány jako vysvětlující proměnná a v grafech je představovány osou x . To je rozdíl oproti učebnicovým modelům, které ji chápou spíše jako proměnou závislou na agregátním množství nabízené práce. To je však problematické, protože, jak jsem naznačil v úvodu, může snadno nastat situace, kdy je nabízeno stejné množství práce za různé mzdy. Naopak nejsou časté situace, kdy za jinak stejných externích

⁴⁴ Ve skutečnosti je samozřejmě možné, aby se zadlužení dostali kvůli nesplaceným úrokům a penále do dluhové pasti, ze které se nemohou dostat nikdy. Tento problém by si jistě zasloužil modelovat, ale vyžadovalo by to jiný typ modelu, který by kladl větší důraz na modelování sociálních parametrů dlužníků a praktik lichvářských firem.

⁴⁵ Pracovník nejprve splatí existenční minimum a případnou splátku dluhu. Pokud je zbytek úspor menší než rozdíl mezi existenčním a statusovým minimem, spotřebuje zaměstnaný i nezaměstnaný agent polovinu svých úspor (kompromis mezi potřebou dosáhnout statusové spotřeby a snahou nechat si železnou rezervu).


Pokud pracovník není zaměstnaný, ale úspory jsou vyšší než statusové minimum, chce se pracovník přiblížit spotřebě na úrovni statusového minima. Spotřebuje nejprve tolik, aby dosáhl poloviny statusového minima. Kolik spotřebuje navíc, závisí na velikosti úspor. Pro úspory nízké, blíží se statusovému minimu, nespotřebuje navíc téměř nic, pro úspory zvyšující se limitně do nekonečna bude se spotřeba limitně blížit druhé polovině statusového minima (celková spotřeba se blíží statusovému minimu).

Pokud je pracovník zaměstnaný a jeho mzda i úspory jsou vyšší než statusové minimum, spotřebuje nejprve tolik, aby dosáhl statusového minima. Kolik spotřebuje ze zbylé mzdy, závisí na velikosti úspor. Pro úspory nízké, blíží se statusovému minimu, nespotřebuje ze zbytku mzdy téměř nic, pro úspory zvyšující se limitně do nekonečna se spotřeba bude limitně blížit celému zbytku mzdy.

Ještě podrobnější popis lze v případě zájmu vyčíst ze zdrojového kódu modelu.

podmínek budou pro jednu úroveň mzdy nabízeny různé hodnoty práce. Výjimkou zde může být vliv zadlužení pracovníků.

Na výši mezd je závislá zaměstnavatelova poptávka po práci. Ve shodě s učebnicovými modely předpokládám, že zaměstnavatel maximalizuje zisk, pokud mzda je rovna příjmu z mezního produktu práce⁴⁶. Proto můžeme příjem z mezního produktu ztotožnit s poptávkou. Důležitým předpokladem a jistým omezením modelu je konstantní velikost kapitálu, a tedy stabilní funkce příjmu z mezního produktu práce. To odpovídá učebnicové situaci v krátkém období. Předpokládáme, že příjem z mezního produktu práce je lineárně závislý na množství práce a je klesající. To znamená, že zaměstnavatelova poptávka po práci bude lineárně klesat s rostoucí mzdou.



Graf 2. – Graf znázorňuje objem mezd (Wages) a zisk zaměstnavatele (Profit) při dané mzdě (Wactual) a odpovídající agregátní nabídce práce (S). Poptávku po práci představuje příjem z mezního produktu MRP. Agregátní nabídka práce je pouze hypotetická, v modelu nemá stabilní podobu a mění se v závislosti na subjektivních preferencích a zadlužení pracovníků. Proto není možno maximalizovat zisk analyticky odvozením křivky mezních nákladů z křivky agregátní nabídky. Zaměstnavatel tedy musí neustále experimentovat se zvyšováním a snižováním mzdy, aby stanovil mzdu maximalizující zisk.

Jak jsem již zmínil, modelujeme dvě možné situace: jednak může být mzda po celou dobu běhu modelu fixní a zaměstnavatel jí jednoduše přizpůsobí poptávku po práci, anebo může zaměstnavatel nabídku práce měnit. První situace nám umožňuje určit, jak se pro různé stabilní hodnoty mezd budou vyvíjet parametry jako je zisk, poptávka po práci, nezaměstnanost, zadluženost pracovníků a jejich úspory.

V druhé situaci mění zaměstnavatel výšku mezd o relativně malou částku a sleduje, zda mu změna nabídky práce, kterou vyvolá změna mezd, přinese vyšší zisk či nikoliv. Pokud se zisk zvýší, pokračuje zaměstnavatel ve změně mezd stejným směrem (tj. stále je zvyšuje nebo snižuje) dokud se zisk zvyšuje. Pokud se zisk sníží, obrátí zaměstnavatel směr změny

⁴⁶ Příjem z mezního produktu práce znamená zvýšení příjmu z produktu získaného každou novou jednotkou práce. Jednotkou práce v tomto modelu nerozumíme jednoho pracovníka navíc, ale jednu hodinu práce navíc. Pokud bychom chtěli trvat na tom, že jednotka práce, která mění mezní produktivitu, je jeden pracovník, mohli bychom to snadno provést tak, že by funkce mezní produktivity nebyla spojitě lineární, ale měla by tvar schodiště – byla by konstantní pro počet hodin odpracovaný jedním pracovníkem a skokově by se měnila u dalšího pracovníka.

mezd. Situace, kdy zaměstnavatel mění mzdy, umožňuje zjistit, za jakých podmínek dotlačí zaměstnavatel mzdy až k existenčnímu minimu a kdy zůstanou mzdy na úrovni umožňující pracovníkům blahobytný život.

Blahobyt je obtížné definovat, protože se na něm podílejí jak nezaměstnanost, tak výše mezd a liší se pro různé počty pracovníků. Nakonec jsem se rozhodl definovat míru blahobytu jako podíl pracovníků, kteří za dobu běhu modelu naspořili desetinásobek statusového minima. V dalším textu budeme pojmem „blahobytný život“ rozumět situaci, která se blíží maximu blahobytu.

Mzdy umožňující pouze existenční minimum představují pro zaměstnavatele vždy globální maximum zisku, neboť pracovníci jsou nuceni nabízet maximum práce za minimální mzdy. Ovšem pokud je počáteční úroveň mezd nastavena dost vysoko, může zaměstnavatel při postupném hledání maxima zisku malými změnami mezd uváznout v lokálním maximu zisku. K tomu dojde tehdy, když nabídka práce bude nižší než je poptávka po práci a zvyšující se mzdy budou pracovníky díky substitučnímu efektu motivovat k výrazně vyšší nabídce práce. To odpovídá situaci, kterou předpokládá učebnicová ekonomie.

Zaměstnavatel však vždy uspokojí jen takovou nabídku práce, která je nižší než poptávka po práci. Pokud se nabídka práce bude zvyšovat nad poptávku, na výši zisku už to mít vliv nebude.

Omezením modelu je abstrahování od trhu s výrobky. Model nezachycuje, zda zaměstnavatel dokáže své výrobky prodat. Předpokládáme předem danou funkci příjmu z mezního produktu práce, která určuje poptávku po práci při daných mzdách. Model nepředpokládá existenci zpětné vazby, díky které by mzdy a poptávka po práci ovlivňovaly příjem z mezního produktu práce. K tomu by docházelo, pokud by například pracovníci nakupovali větší část zboží vyráběného zaměstnavatelem. Pak by nízké mzdy, nebo nízká zaměstnanost mohl vést k poklesu poptávky po tomto zboží v důsledku snížení kupní síly pracovníků. V globalizovaném světě se však často zboží vyváží a spotřebuje v zahraničí nebo na jiném místě, než je vyráběno. Zaměstnavatel tak může snížení kupní síly svých pracovníků kompenzovat zvětšením množství vyváženého zboží. Pro takového zaměstnavatele je předpoklad pevné funkce příjmu z mezního produktu ospravedlnitelný.

7.2.3.2. Výběr pracovníků

Pokud je agregátní nabídka práce nižší než poptávka zaměstnavatele, přijme zaměstnavatel všechny zaměstnance, až na ty, kteří nemohou být přijati kvůli strukturální nezaměstnanosti (v modelu je její výše 3%).

Pokud je nabídka práce vyšší než poptávka, přijímá zaměstnavatel do práce nejprve ty pracovníky, kteří už v minulém kole pracovali. S jistou nízkou pravděpodobností (v modelu 0.02) jsou však někteří pracovníci zaměstnaní v minulém kole propuštěni (přirozená fluktuace). Teprve poté jsou přijímáni další pracovníci, až dokud není poptávka uspokojena. Navíc jsou přednostně přijímáni ti pracovníci (ať už byli nebo nebyli v předchozím kole zaměstnaní), kteří nabízejí více práce (což je dáno buď jejich vyšším statusovým minimem nebo zadlužeností nebo obojím).

Jedním z největších zjednodušení modelu je to, že zaměstnavatel nerozlišuje kvalifikaci, schopnosti nebo různé pracovní pozice pracovníků a všichni dostávají stejnou hodinovou mzdu. To je samozřejmě nerealistické, pokud bychom modelovali celou škálu pracovních příležitostí. Ale pro užší profesní skupinu jako jsou třeba dělnické profese, státní správa nebo střední management platí, že jejich mzdy zůstávají v relativně kompaktních mzdových mantinelech, kde rozdíly mezi nejnižší a nejvyšší odměnou nedosahují řádových rozdílů. Stejně mzdy pro všechny pracovníky proto můžeme chápat jako hrubou aproximaci platů v nějaké profesní skupině.

7.2.3.3. Interakce mezi pracovníky probíhá nepřímo přes zaměstnavatele

Pracovníci spolu přímo neinteragují. To odpovídá situaci atomizovaných pracovníků, kteří nejsou schopni se sdružovat do odborových hnutí nebo se jinými politickými prostředky bránit snižování mezd.

Pracovníci však spolu interagují nepřímo skrze zaměstnavatele. Pokud je poptávka po práci nižší než nabídka, vzájemně se vytlačují z práce. Zaměstnaný pracovník, který si nevzal půjčku a pobírá mzdu dostačující na zaplacení existenčního minima, nabízí méně práce než agent se stejným statusovým minimem, který si půjčku vzal. Pracovník, který nemá práci, rychle spotřebuje případné úspory, musí si vzít půjčku a začne nabízet více práce. Zaměstnavatel preferuje pracovníky nabízející více práce. Nezaměstnaní pracovníci s půjčkou tedy vytlačují zaměstnané pracovníky bez půjčky.

7.2.4. Možná rozšíření modelu

V modelu není zahrnut vliv velikosti úspor na nabízenou práci (pouze vliv úspor na velikost spotřeby). Můžeme ale předpokládat, že kdyby pracovníci v důsledku důchodového efektu nabízeli méně práce při vyšších úsporách, vedlo by to při vyšší nezaměstnanosti k jejich vytlačení ze zaměstnání, neboť zaměstnavatelé preferují pracovníky nabízející více práce. Poté, co by takoví pracovníci přišli o zaměstnání, vyčerpali by úspory a museli by si vzít půjčky, začali by nabízet více práce. Mezitím by zaměstnaní pracovníci splatili své půjčky a dosáhli vyšších úspor, což by je vedlo ke snižování nabídky práce. Docházelo by tedy k podobnému, ale výraznějšímu vzájemnému vytlačování z práce, které jsem popsal v předchozí kapitole.

Model by šlo dále rozšířit o vliv veřejných sociálních služeb jako je podpora v nezaměstnanosti. Ta by snižovala zadlužování nezaměstnaných agentů a tím snižovala nabídku práce.

Zaměstnavatelé by naopak mohli zvyšovat nabídku práce např. importem pracovníků ze zahraničí nebo zvyšováním pravděpodobnosti půjček a statusové spotřeby pomocí reklamních kampaní. Další možností jak zvýšit nabídku práce by byla inflace nebo zvyšování cen základních potřeb (např. pomocí zvýšení spotřebních daní). Zaměstnavatel by se také mohl pokoušet uplatňovat mzdovou diskriminaci pracovníků s větší statusovou potřebou (kteří mají pro některé rozsahy mezd nižší elasticitou nabídky práce).

Zaměstnanci by také mohli upravovat svoji statusovou potřebu podle průměrných nebo mediánových úspor celé populace. Při rostoucích úsporách celé populace by se začala zvyšovat i statusová potřeba motivovaná snahou vyhnout se zařazení do sociálně slabší vrstvy. To by zesilovalo vliv substitučního efektu a zvyšovalo nabídku práce. Pokud by úspory celé populace klesaly, vedlo by to ovšem k efektu opačnému.

V modelu přímo nepracuji s minimální mzdou, ale díky extenzivnímu výzkumu chování modelu při různých hodnotách fixních mezd můžeme odvodit i vliv případných minimálních mezd na chování modelu – viz Závěr.

7.2.5. Formální popis modelu

Stav pracovníka i v čase t můžeme vyjádřit:

$$a_{i,t} = (s_{i,t}, d_{i,t}, emp_{i,t}, L_{i,t})$$

Zde $s_{i,t}$ označuje úspory, $d_{i,t}$ označuje dluh, $emp_{i,t}$ označuje zda byl pracovník v čase t zaměstnán (hodnota nabývá booleovských hodnot true/false) a $L_{i,t}$ označuje kolik práce pracovník nabízí. Výše úspor a dluhu představuje jakousi minimální paměť o minulých stavech modelu, agenti však nejsou schopni žádného typu učení.

Stav zaměstnavatele E_t v čase t můžeme vyjádřit:

$$E_t = (W_t, R_t)$$

Zde W_t je výše hodinové mzdy a R_t je zisk dosažený v daném období.
Funkci určující chování pracovníka i můžeme vyjádřit:

$$f_i(a_{i,t-1}, E_{t-1}) = a_{i,t}$$

Pracovník je závislý na svém minulém stavu a na výši mezd a poptávce po práci, které určuje zaměstnavatel.

Funkci určující chování zaměstnavatele můžeme vyjádřit:

$$f_E(a_{1,t-1} \dots a_{k,t-1}) = E_t$$

Zaměstnavatel je závislý na nabídce práce všech pracovníků.

V situaci s fixní mzdou se mění pouze zisk zaměstnavatele. V situaci s pohyblivou mzdou může zaměstnavatel reagovat na měnící se zisk i změnou mezd.

7.3. Nastavení modelu

Pro všechny běhy modelu byly fixně nastaveny následující parametry:

Na straně pracovníků:

- Existenční minimum: 1000
 - *Poznámka: Hodnoty ex. minima a mezd jsou v abstraktních měnových jednotkách.*
- Exponent užitku ze statusové spotřeby: 1.85
- Exponent negativního užitku z času obětovaného práci: 0.85
- *Poznámka: Velikosti exponentů byly nastaveny tak, aby individuální nabídkové funkce odpovídaly předpokládané nabídce v realitě. K přesnější kalibraci by byl potřeba empirický výzkum.*

Na straně zaměstnavatele:

- Strukturální nezaměstnanost: 3%
- Pravděpodobnost propuštění: 0.02
- Příjem z mezního produktu, resp. poptávková funkce byla dána lineární rovnicí: $L = 2000 - W$
 - *Poznámka: Při nulové mzdě je tedy zaměstnavatel ochoten poptávat za časovou jednotku průměrně 2000 člověkohodin práce denně. S rostoucí mzdou (odpovídající příjmu z mezního produktu) se poptávané množství práce lineárně snižuje se směrnici -1. Zaměstnavatel přestává poptávat práci při velikosti hodinové mzdy 2000.*

Při opakovaných spouštěních modelu pro tu samou velikost populace byly hodnoty statusových potřeb v populaci pracovníků stejné⁴⁷.

⁴⁷ Díky stejnému „seed“ generátoru náhodných čísel. U ostatních náhodných akcí (např. propouštění ze zaměstnání), byl nastaven náhodný seed.

Proměnné parametry byly počáteční velikost mezd, počet pracovníků a pravděpodobnost, že si pracovník vezme spotřební půjčku.

Experimenty s modelem zkoumaly dvě různé situace: situaci s fixní mzdou a situaci s pohyblivou mzdou (podrobně popsane v předchozí kapitole o zaměstnavateli). V obou situacích byly počáteční hodnoty hodinových mezd nastavovány pro různé běhy modelu v rozmezí 50 až 1500 s krokem 10. Hodnota mzdy 50 je ještě o něco nižší, než stačí na zajištění existenčního minima. V realitě by samozřejmě taková situace vedla ke společenským nepokojům, stávkám apod. Při maximální individuální nabídce práce 14hodin denně lze vydělat na existenční minimum ve výši 1000 až při hodinové mzdě cca 71.43.

V situaci s fixní mzdou byla mzda nastavena na začátku a zaměstnavatel nemohl mzdu měnit. Počet pracovníků byl nastavován na hodnoty: {100, 200, 300}. Pravděpodobnost půjček byla nastavována na hodnoty: {0, 0.05, 0.1, 0.15, 0.2}. Každý běh modelu trval 100 kroků. Celkově bylo provedeno 2190 běhů modelu s tímto nastavením.

V druhé situaci mohl zaměstnavatel mzdu měnit o plus nebo minus 10 peněžních jednotek. Počet pracovníků byl nastavován na hodnoty: {100, 150, 175, 185, 200}. Pro počet pracovníků vyšší jak 200 dotlačil zaměstnavatel mzdy téměř vždy pod existenční minimum. Pravděpodobnost půjček byla nastavována v rozmezí 0 až 0.2 s krokem 0.005. Tento relativně jemný krok umožnil podrobnou analýzu kritických přechodů od výsledných mezd umožňujících blahobytný život ke mzdám, které neumožňují ani dosažení existenčního minima. Každý běh modelu trval 150 kroků. Celkově bylo provedeno 29930 běhů modelu s tímto nastavením.

7.4. Výsledky experimentů

7.4.1. Situace s fixní mzdou

Výsledky experimentů v situaci s fixní mzdou jsou zachyceny na grafech na následujících dvou stranách. Grafy 3.-23. jsou organizovány v tabulce. Řádky zachycují vývoj několika klíčových parametrů pro různé počáteční hodnoty mzdy (které zůstávají fixní po dobu běhu modelu). Barevně jsou odlišeny hodnoty pro různou pravděpodobnost půjček. V levém sloupci jsou hodnoty pro 100 pracovníků, v prostředním pro 200 pracovníků a v pravém pro 300 pracovníků. Každý bod v grafech v jednom řádku (tj. pro jeden parametr) odpovídá jednomu z konečných stavů 2190 běhů modelu. V prvním řádku, v pravém grafu je pomocná tabulka popisující barevné odlišení hodnot pro různé pravděpodobnosti půjček.

V prvním řádku sledujeme vývoj zisku zaměstnavatele. Vidíme, že zisk má globální maximum vždy pro minimální mzdu. Pro nižší počet pracovníků (tj. nižší agregátní nabídku práce) a nižší pravděpodobnost půjček existuje i lokální maximum zisku. Toto lokální maximum se objevuje při takových hodnotách mezd, kdy snížení/zvýšení mezd vede k relativně výraznému snížení/zvýšení nabídky práce. Pro větší míru zaměstnanosti a vyšší pravděpodobnost spotřebních půjček toto maximum mizí a objevuje se pouze pomalejší růst zisku při snižování mezd.

V druhém řádku sledujeme vývoj uspokojení nabídky práce (měřené v průměrných hodinách práce za den). Vidíme, že při velmi nízkých mzdách jsou pracovníci nuceni nabízet maximum práce, se zvyšujícími se mzdou klesá nabízená práce až do okamžiku, kdy převládne substituční efekt. Pokles zisků zaměstnavatele souvisí právě s tímto poklesem nabídky práce. Při dalším zvyšování mezd může zaměstnavatel dosáhnout lokálního maxima zisků ve fázi vzestupu nabídky práce, ale ještě předtím než nabídka práce dosáhne poptávky po práci. V tomto bodě se vývoj uspokojené nabídky práce láme a se zvyšující mzdou kopíruje křivku poptávky po práci (zaměstnavatel poptává méně práce, než činí nabídka).

Ve třetím řádku sledujeme vývoj nezaměstnanosti. Nezaměstnanost vzniká, když je nabídka práce vyšší než poptávka. Pro nižší počet pracovníků není znát vliv pravděpodobnosti

půjček. Teprve u vysokého počtu pracovníků je zřetelné, že vyšší pravděpodobnost půjček vede k nárůstu nabídky práce a následně k růstu nezaměstnanosti. Zadlužení pracovníci nabízejí více práce a navzájem se tak vytlačují ze zaměstnání.

Ve čtvrtém řádku sledujeme procento zadlužených pracovníků. Není zde rozlišeno, zda je jejich zadlužení malé či velké. Zadlužení může být jak důsledkem toho, že pracovník nemá na existenční minimum, tak toho, že si vezme spotřební půjčku. Připomeňme, že spotřební půjčku si pracovníci mohou vzít, jen pokud jsou aktuálně zaměstnáni a mají nenulové úspory. Pro nižší pravděpodobnosti spotřebních půjček je zřetelná závislost procenta zadlužených na nezaměstnanosti – musí si brát půjčky, aby splatili existenční minimum. Pro vysoké pravděpodobnosti spotřebních půjček a nízké mzdy je tato závislost zřetelná méně, neboť je zadlužena většina pracovníků. I zaměstnaní pracovníci se nyní zadlužují, berou si spotřební půjčky, které jsou desetinásobně vyšší než existenční minimum a proto nestačí půjčky splácet. S rostoucími mzdami začne počet zadlužených pracovníků klesat, neboť je stále snazší půjčky splácet. Od jisté výše mezd se však začne projevovat převis nabídky práce nad poptávkou a počet zadlužených klientů začne kopírovat počet nezaměstnaných. V této fázi přestává být zřetelný vliv velikosti půjček na počet zadlužených pracovníků.

V pátém a šestém řádku sledujeme vývoj průměrných úspor a dluhu. Maximum úspor dosahují pracovníci v situaci, kdy je malá část pracovníků nabízejících nejvíce práce zaměstnána za extrémně vysoké mzdy, přičemž zbytek je nezaměstnaný. V této situaci je nabídka práce vyšší než poptávka po práci. Zaměstnavatelé nerealizují maximum zisků. Tato situace je tedy nepříznivá jak z hlediska velké části pracovníků, tak z hlediska zaměstnavatele.

Při extrémně nízkých mzdách je zadlužení vysoké pro všechny počty pracovníků, neboť ani zaměstnaní pracovníci nejsou schopni vydělat existenční minimum. Pro vyšší počty pracovníků se při velmi nízkých mzdách navíc projevuje vliv nezaměstnanosti. Při nízkých mzdách a plné zaměstnanosti je zadlužení nejprve relativně nízké⁴⁸. Zaměstnanci si sice vezmou spotřební půjčky, ale jejich mzda je celá spotřebována na splácení půjčky, takže nic nenaspóří a díky tomu si nemohou znovu půjčit. Když se ale mzdy zvýší, vydělávají zaměstnanci více, než vydají na splátkách a při vysokých pravděpodobnostech půjček si začínají brát další a další půjčky a celkový dluh začne růst. Při ještě vyšších mzdách jsou zaměstnanci schopni splácet půjčky ve stále kratším intervalu a dluh začne klesat. Nakonec vydělávají pracovníci tolik, že půjčku splatí z úspor okamžitě a vliv spotřebních půjček na dluh je eliminován. Při vysokých mzdách se však začne projevovat vliv vzrůstající nezaměstnanosti, která vede ke vzrůstu dluhu v důsledku půjček na splacení existenčního minima.

V sedmém řádku (na další straně nahoře) sledujeme vývoj blahobytu, který jsem definoval jako podíl pracovníků, jejichž úspory dosáhly na konci běhu modelu alespoň desetinásobku statusového minima potřeby. Nejvyšší míra blahobytu je dosahována při vyšším počtu pracovníků pro nižší mzdy, což je dáno zejména tím, že pro vyšší počty pracovníků začíná růst nezaměstnanost při nižších úrovních mezd. Můžeme si všimnout, že maxima blahobytu je dosaženo při o něco nižších mzdách, než je dosaženo maxima úspor – viz výše odstavec o úsporách. Vliv pravděpodobnosti spotřebních půjček na snižování blahobytu je zřetelný zejména při mzdách, které nejsou ani příliš nízké, ani příliš vysoké. Při

48

Při nižších mzdách se pro vysoké pravděpodobnosti půjček objevují v grafu ojediněle i velmi vysoké hodnoty dluhu. Nedokázal jsem s jistotou identifikovat důvod. Předpokládám, že vliv by mohl mít jeden z artefaktů modelu: Model běží relativně krátce – sto kroků. Při vysokých pravděpodobnostech půjček si pracovníci na začátku téměř zároveň (v průběhu několika málo kroků) nabírají půjčky, které pak (díky nízkým mzdám) relativně dlouho splácejí. Splatí je pak opět téměř zároveň a znovu si nabírají půjčky. Díky tomu se může při některých hodnotách (nízkých) mezd stát, že po sto krocích dojde k tomu, že velká část pracovníků si právě nabírá půjčky a jen málo pracovníků má půjčky víceméně splacené nebo je bez dluhu.

nízkých mzdách je blahobyt nízký pro všechny pravděpodobnosti půjček. Při vysokých mzdách jsou všichni zaměstnaní pracovníci schopni pro všechny pravděpodobnosti půjček ušetřit desetinásobek statusového minima a velikost blahobytu bude pro danou mzdu záviset hlavně na míře nezaměstnanosti.

Grafy 24.-27. zachycující závislost některých klíčových parametrů na pravděpodobnosti spotřebních půjček. Jednotlivé body v grafech zachycují průměr dané hodnoty pro různé mzdy, horní a dolní meze značí 90% interval spolehlivosti. Barevně rozlišené jsou spojnice pro různé hodnoty počtu pracovníků.

Na grafu vlevo nahoře vidíme vývoj zisku. Zisk se vždy zvyšuje se zvyšující se pravděpodobností spotřebních půjček. To je důsledek zvýšené nabídky práce zadlužených. Zvýšená nabídka práce vždy buď zisk zvýší, nebo ho nechá beze změny.

Na grafu vpravo nahoře vidíme vývoj nezaměstnanosti. S výjimkou nízkého počtu pracovníků, kdy je nabídka práce vždy uspokojena, roste nezaměstnanost s pravděpodobností spotřebních půjček.

Na spodních grafech vidíme vývoj průměrného zadlužení a úspor. Dluhy rostou a úspory klesají se zvyšující se pravděpodobností spotřebních půjček.

7.4.2. Situace s pohyblivou mzdou

Výsledky situace, kdy zaměstnavatel může mzdu postupně měnit, zachycují obrázky 1.-5. Na obrázcích je pět matic, které směrem shora dolů zachycují výsledky pro postupně narůstající počty pracovníků. Body v každé matici představují výslednou mzdu, ke které zaměstnavatel dospěl po 150 krocích běhu modelu pro parametry dané na osách x a y . Na ose x jsou hodnoty počáteční mzdy v rozmezí 50 až 1500 s krokem 10. Na ose y jsou pravděpodobnosti spotřebních půjček v rozmezí 0 až 0.2 s krokem 0.005. Čím světlejší je barva bodů, tím je výsledná mzda vyšší. Maximum světlosti by odpovídalo mzdě 900, této hodnoty však výsledná mzda nikdy nedosáhne a dosahuje nejvýše hodnoty 730. Červená barva bodů znamená, že počáteční mzda byla nižší než výsledná a zaměstnavatel maximalizoval zisk zvýšením mezd. Modrá barva bodů znamená, že počáteční mzda byla vyšší než výsledná a zaměstnavatel maximalizoval zisk snížením mezd. Tmavě modrá barva (která vypadá jako černá) odpovídá výsledné mzdě, která nedostačuje ani k existenčnímu minimu.


Pokud jsou počáteční mzdy dost nízké, nabídka práce se zvyšuje se snižujícími se mzdami (aby mohli pracovníci při nízkých mzdách zaplatit existenční minimum) a zaměstnavatel bude vždy maximalizovat zisk tím, že dotlačí mzdy až k, nebo pod existenční minimum.


Pro velmi nízký počet pracovníků ($n = 100$) nedotlačí zaměstnavatel od jisté velikosti počáteční mzdy výslednou mzdu pod existenční minimum ani pro relativně vysoké hodnoty pravděpodobnosti spotřebních půjček. To je dáno tím, že i když je většina pracovníků zadlužena a nabízí proto více práce, jejich počet je tak malý, že agregátní nabídka práce je stále nižší než poptávka po práci. Zaměstnavatel uvízne v lokálním maximu zisku, protože pokud by snižoval mzdy, pokles nabídky práce by byl tak výrazný, že by se zisk snižoval. Mzdy se udrží na úrovni umožňující pracovníkům blahobytný život.

Pro vyšší počty pracovníků je zřetelné, že zvýšení pravděpodobnosti půjček nad jistou kritickou hodnotu vede k tomu, že pro jakoukoliv počáteční mzdu dotlačí zaměstnavatel výslednou mzdu k existenčnímu minimu. Tato kritická hodnota pravděpodobnosti půjček klesá se zvyšujícím se počtem pracovníků.


Pro nižší než kritické hodnoty pravděpodobnosti půjček vidíme, že s rostoucím počtem pracovníků se také zužuje rozsah počátečních mezd, které vedou zaměstnavatele k lokálnímu maximu zisku (tj. nedotlačí mzdy až k existenčnímu minimu). Zužuje se rozsah počátečních mezd, pro něž bude výsledná mzda vyšší (červené body) i nižší (modré body). Světlé body tvoří kupovitý tvar. Důvodem je to, že při vysokých počátečních mzdách je díky nižší

poptávce po práci vyšší nezaměstnanost, díky které se pracovníci zadluží. Zaměstnavatel postupně sníží mzdu až k hodnotě, která by pracovníkům umožňovala blahobytný život a zaměstnavatel by zde uvázl v lokálním maximu zisku (kdyby počáteční mzdy byly na této úrovni). Ale v důsledku vysokého počtu pracovníků, kteří se mezitím stihli zadlužit a nabízejí větší množství práce, lokální maximum zaniká a zaměstnavatel může zvyšovat zisk při snižujících se mzdách až k existenčnímu minimu.






Grafy 3.-23. – Hodnoty zisku, uspokojené nabídky práce, nezaměstnanosti, zadlužených pracovníků, průměrných úspor, průměrných dluhů a blahobytu na konci běhu pro různé hodnoty fixních mezd a kombinace počtu pracovníků a pravděpodobnosti půjčky.



Grafy 24.-27. – Průměrné hodnoty zisku nezaměstnanosti, dluhu a úspor při fixní mzdě pro různé kombinace počtu pracovníků a pravděpodobnosti půjčky.



Obr. 1.-5. – Matice zachycující vývoj trhu v situaci s pohyblivou mzdou pro různé počty pracovníků a kombinace počáteční mzdy a pravděpodobnosti půjček. Na ose x jsou hodnoty počáteční mzdy v rozmezí 50 až 1500 s krokem 10. Na ose y jsou pravděpodobnosti spotřebních půjček v rozmezí 0 až 0.2 s krokem 0.005. Čím světlejší je barva bodů, tím je výsledná mzda vyšší.

7.5. Závěr

V rámci zde popsaného modelu je patrné, že pokud se v některých lokalitách nebo pro jisté profesní skupiny blíží trh práce situaci monopsonu, pak je zájmem zaměstnavatele maximalizujícího zisk snížit mzdy až na hranici existenčního minima. Při nízkém počtu pracovníků a nízké pravděpodobnosti půjček se však může stát, že zaměstnavatel, který mění mzdy jen po relativně malých krocích, uvázne v lokálním maximu zisku při velikosti mezd, která umožňuje pracovníkům blahobytný život.

Samozřejmě, kdyby zaměstnavatel mzdy snižoval dost dlouho (riskoval přitom krátkodobé snížení zisku), nebo kdyby mzdy snížil o velkou částku, mohl by se dostat do stejné situace, jaká nastává při nízkých počátečních mzdách. Takový manévr však model neumožňuje, protože předpokládáme, že tomu brání různá institucionální omezení. Je pravděpodobnější, že se zaměstnavatel bude spíše snažit snižovat mzdy postupně a minimalizovat svůj ušlý zisk podporou nabídky práce. Nabídku práce může podpořit nejen podpora spotřebních půjček, ale i další faktory zesilující obavy z nezaměstnanosti, které model nezachycuje, jako jen např. oslabování veřejných sociálních služeb⁴⁹, dočasný import pracovní síly ze zahraničí a další opatření popsaná v kapitole 7.2.4.

Zaměstnavatel může též využívat kombinace obav ze ztráty zaměstnání a zadluženosti a sáhnout k podobným opatřením, jaké popisuje úvodní motto, kdy jsou zaměstnanci nuceni dělat neplacené přesčasy. To přesně odpovídá situaci, ve které se snižují průměrné hodinové mzdy a zvyšuje se nabídka práce.

Zájmem pracovníků je naopak bránit se buď zavedením minimální mzdy, nebo alespoň nedovolit zaměstnavateli příliš velké snižování mezd, což může vést k tomu, že zaměstnavatel uvázne v lokálním maximu zisku. Pro pracovníky jako jednotlivce i skupinu je vysoce rizikové i při relativně vysokých mzdách a úsporách nejen brát si spotřební půjčky, ale i nechat se nadměrně motivovat statusovou spotřebou k vysoké nabídce práce. Vysoká nabídka práce představuje riziko, že jejich zaměstnavatelé budou moci v dlouhodobém horizontu stlačit mzdy na podstatně nižší hodnotu. Pracovníci nabízející hodně práce vytlačují ze zaměstnání ostatní pracovníky a ti se postupně dostávají do dluhů nikoliv kvůli spotřebním půjčkám, ale kvůli půjčkám nutným na splacení existenčního minima. Nezaměstnanost nevzniká jen v důsledku nechuti nezaměstnaných pracovat, ale i v důsledku toho, že je jejich „šťastnější“ kolegové vytlačili ze zaměstnání.

Model sice přímo neřeší otázku minimální mzdy, ale ukazuje následující skutečnosti: Pokud jsou mzdy tak vysoké, že agregátní nabídka práce roste se zvyšujícími se mzdami, pak můžeme souhlasit s učebnicovou ekonomickou teorií, že zvýšení minimálních mezd bude zvyšovat nezaměstnanost (ovšem jen pokud agregátní nabídka práce převyšuje poptávku). Model však ukazuje i to, že pokud jsou minimální mzdy tak nízké, že agregátní nabídka práce roste se snižujícími se mzdami, pak povede ke zvýšení nezaměstnanosti naopak další snížení či dokonce zrušení minimálních mezd.

Všechny zde uvedené závěry jsou samozřejmě platné jen v rámci zjednodušujících předpokladů, které jsem stanovil při tvorbě modelu. Aplikace těchto závěrů v reálném světě by bylo nutné doplnit empirickým výzkumem konkrétních ekonomických, sociologických a psychologických ukazatelů.

⁴⁹

Zejména podpory v nezaměstnanosti, podpory rodin s dětmi, zdravotnictví a školství.

8. Závěr

8.1. Dosažené výsledky

V první části této práce jsem na základě syntézy mnoha zdrojů vytvořil návrh metodologie multiagentních modelů sociálních systémů. Tuto metodologii jsem ilustroval rozbořením již existujícího a dobře známého modelu etnocentrického chování. Podrobně jsem se věnoval zejména komplexitě a samoorganizaci a prakticky aplikoval a sledoval vývoj různých typů strukturální komplexity. Dále jsem se pokusil vysvětlit hlavní odlišnosti mezi multiagentními modely a analytickými modely, které jsou využívány v ekonomii hlavního proudu. Domnívám se, že tato část může sloužit jako úvod do problematiky multiagentních modelů a je použitelná i jako učebnice.

Druhá část ukazuje praktické aplikace multiagentních modelů v ekonomii. Tři modely, které jsou zde popsány, mohou sloužit jako podrobně řešené příklady. Tyto modely však nebyly vytvářeny jen pro pedagogické účely. Všechny modely mají výzkumný charakter a ukazují alternativní přístup k modelování některých typických ekonomických situací. Alternativa spočívá zejména v opuštění předpokladů racionality agentů. Soustředil jsem se na modely s reaktivními agenty, neboť reaktivitu chápu jako vhodný způsob modelování omezené racionality. Konkrétně:

- V modelu transakčních nákladů na finančním trhu se omezená racionalita projevuje stádním chováním, zašuměním zpráv a náhodným faktorem chování agentů.
- V modelu evoluce averze k riziku a nejistotě se u agentů vyvíjí „emoce“, která ovlivňuje rozhodování. Tento vliv může být zdánlivě iracionální z hlediska jednoho rozhodnutí, ale je racionální z hlediska dlouhodobě opakujícího se rozhodování.
- V modelu monopsonu na trhu práce se omezená racionalita projevuje jako neschopnost agentů racionálně očekávat, že díky svému zadlužení umožní zaměstnavatelům snižovat mzdu.

Model transakčních nákladů na finančním trhu jsem založil na již hotovém modelu, který ukazoval, jakým způsobem vzniká díky omezené racionalitě agentů nestabilita na finančních trzích. Nestabilita na finančních trzích je v rozporu s tzv. Hypotézou efektivního trhu. Původní model jsem modifikoval, doplnil o působení transakčních nákladů a zkoumal jak nestabilitu a neefektivitu trhu ovlivňuje výše transakčních nákladů. Zjistil jsem, že transakční náklady vedou ke snižování nestability trhu, snižování objemu obchodu a do jisté míry mohou zvyšovat efektivitu trhu. Přes jednoduchost modelu mohou být dosažené výsledky nápovědou pro rozhodování institucí, které mohou finanční trhy regulovat.

Model evoluce averze k riziku a nejistotě je inspirován psychologickými a neurologickými důkazy, které zpochybňují tzv. Hypotézu očekávaných užitků. Model ukazuje, že existuje velmi jednoduchý evoluční mechanismus, který povede ke vzniku averze k riziku a nejistotě. Tato averze se vyvinula díky situacím, kdy se agent může opakovaně rozhodovat a získávat odměnu a zároveň existuje šance, že díky některým, z krátkodobého hlediska výhodným, volbám ztratí možnost pokračovat v získávání odměny. Sexuální reprodukce vznik této averze podporuje. Pokud se tato averze vyvinula i u lidí, může ovlivňovat i jednorázové rozhodování a vést k chování, které je „neracionální“, resp. v rozporu s Hypotézou očekávaného užitku. Tento závěr jsem aplikoval na vysvětlení tzv. Allaisova paradoxu.

Model monopsonu na trhu práce zkoumá situaci, kdy zaměstnavatel může díky své síle snižovat mzdy až existenčnímu minimu. Pracovníci jsou v takovém případě „paradoxně“ nuceni zvyšovat nabídku práce při snižujících se mzdách. Tato situace stojí mimo zájem hlavního proudu ekonomické teorie. Model dále zkoumá vliv spotřebních půjček na zisky zaměstnavatele, výši mezd, nezaměstnanost a blahobyt. Model ukazuje, že zvyšování pravděpodobnosti, že si pracovníci vezmou spotřební půjčku, zvyšuje zisky zaměstnavatelů, zvyšuje nezaměstnanost, snižuje blahobyt a v některých situacích umožňuje zaměstnavatelům snížit mzdy až k existenčnímu minimu pracovníků. Model také napovídá, že pro velmi nízké úrovně mezd povede snížení minimálních mezd „paradoxně“ ke zvýšení nezaměstnanosti. V závěru vyvozují doporučení jak pro zaměstnavatele snažící se maximalizovat zisk, tak pro zaměstnance bránící se snižování mezd.

8.2. *Budoucnost multiagentních modelů*

Tvůrci multiagentních modelů často doufají, že jejich modely by měly vést k nějakému nečekanému výsledku, zejména k jevům, které vznikají v důsledku samoorganizace. Nebo se alespoň snaží odhalit mechanismy, které k takovým jevům vedou.

V modelech, které popisují v této práci, dochází k jevům, které by bylo možno nazvat samoorganizací, pouze v modelu etnocentrického chování (v důsledku lokality interakcí a reprodukce) a v modelu transakčních nákladů na finančních trzích (v důsledku stádního chování agentů). Model evoluce averze k riziku a nejistotě i model monopsonu na trhu práce jsou spíše ilustrací dynamiky komplexního systému v zajímavé situaci. Právě k takovému využití jsou multiagentní modely mimořádně vhodné. V této práci jsem ukázal i toto méně „efektní“ využití multiagentních modelů.

Doufám, že tato práce přispěje výuce ekonomů a sociologů, kteří budou multiagentní modely využívat nejen jako exotickou hračku, ale jako nástroj, kterým je možno popsat téměř neomezené spektrum sociálních systémů. Domnívám se dokonce, že tvorba jednoduchých multiagentních modelů by se v budoucnu mohla stát pro ekonomy a sociology běžnou dovedností.

K tomu je na jedné straně třeba, aby nástroje pro multiagentní modelování byly přístupné i neinformatikům. Na straně druhé je nutná ochota společenských vědců naučit se s těmito nástroji zacházet, což bude asi vždy zahrnovat i základní programátorské schopnosti. Vzhledem k tomu, jak sofistikované analytické a statistické nástroje se ve společenských vědách využívají, nevidím důvod, proč by společenští vědci nedokázali zvládnout i nástroje pro multiagentní modelování. Složitější modely bude ovšem vhodnější vytvářet v transdisciplinárních týmech, kde odborník na multiagentní modelování navrhne nejvhodnější architekturu modelu na základě požadavků ekonomů či sociologů.

Multiagentní modelování nás nutí přistupovat k modelování konstruktivně. Nestačí zde pouhá teoretická tvrzení, že existuje nějaké řešení, ale jsme nuceni zkonstruovat způsob jak řešení dosáhnout. To nás vede k nutnosti uvědomit si, jaké obrovské množství zjednodušujících předpokladů při modelování sociálních systémů přijímáme. Multiagentní

modely nám sice umožňují opustit některá zjednodušení, která přijímají např. analytické ekonomické modely, přesto jsou multiagentní modely stále často jen hračky – „toy model“.

Se zvyšujícím se výkonem výpočetní techniky a technologií automatického sběru a sémantické analýzy dat by v budoucnosti mohlo být stále snazší vytvářet složité modely kalibrované na reálná data. Multiagentní modely by se mohly stát praktickým nástrojem běžně využívaným deduktivně pro předpověď vývoje reálných systémů. Ale všechny modely předpovídající vývoj lidské společnosti jsou v jistém smyslu omezené. Lidé totiž mohou v důsledku znalosti předpovědi změnit své chování. Dochází tak ke zpětné vazbě mezi předpovědí a lidským chováním. Předpověď se může stát vodítkem, jak předpovídanému vývoji zabránit. Ale stejně tak se může stát sebenaplnujícím proroctvím, které nás přiměje k tomu, abychom ho uskutečnili.

9. Literatura

1. Allais, M. (1953). Le comportement de l'homme rationnel devant le risque: critique des postulats et axiomes de l'école Américaine. *Econometrica*, 1953, no. 21, p. 503-546.
2. Arthur, W.B., J.H. Holland, B. LeBaron, R. Palmer, and P. Taylor. (1997). Asset pricing under endogenous expectations in an artificial stock market. In W.B. Arthur, S.N. Durlauf, and D.A. Lane (eds) *The Economy as an Evolving Complex System II* Reading, MA: Addison-Wesley, pp. 15-44.
3. ASCAPE. (2010). [online]. [cit. 1.5.2010]. Dostupné na WWW: <<http://ascape.sourceforge.net/>>.
4. Axelrod, R. (1987). The Evolution of Strategies in the Iterated Prisoner's Dilemma. In Lawrence Davis (ed.), *Genetic Algorithms and Simulated Annealing*. London: Pitman, and Los Altos, pp. 32-41. Dostupné na WWW: <<http://www-personal.umich.edu/~axe/research/Evolving.pdf>>.
5. Axelrod, R. (2003). Advancing the Art of Simulation in the Social Sciences. *Japanese Journal for Management Information System*, Special Issue on Agent-Based Modeling, Vol. 12, No. 3, Dec. 2003.
6. Axelrod, R. Tesfatsion, L. (2005). A Guide for Newcomers to Agent-Based Modeling in the Social Sciences. In Tesfatsion, L. and Kenneth, J. (Eds.), *Handbook of Computational Economics, Vol. 2: Agent-Based Computational Economics*. Handbooks in Economics Series, Elsevier/North-Holland, Amsterdam, the Netherlands, 2006. Dostupné na WWW: <<http://www.econ.iastate.edu/tesfatsi/GuidetoABM.pdf>>.
7. Axtell, R. (1999a). Why Agents? On the Varied Motivations for Agent Computing in the Social Sciences. *Agent Simulation: Applications, Models, and Tools*, 1999. Dostupné na WWW: <http://www.brookings.edu/reports/2000/11technology_axtell.aspx>.

8. Axtell, R. (1999b). *The Emergence of Firms in a Population of Agents*. Working paper. Dostupné na WWW: <www.brookings.edu/es/dynamics/papers>.
9. Axtell, R. (2000). *The Complexity of Exchange*. Working paper. The Brookings Institution. Dostupné na WWW: <www.brookings.edu/es/dynamics/papers>.
10. Bakshy, E. and Wilensky, U. (2007). *NetLogo Team Assembly model*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. Dostupné na WWW: <<http://ccl.northwestern.edu/netlogo/models/TeamAssembly>>.
11. Box, George E. P.; Norman R. Draper (1987). *Empirical Model-Building and Response Surfaces*. Wiley. pp. p. 424
12. Bratley, P., Fox, B. & Schrage, L. (1987). *A Guide to Simulation. Second Edition*. New York: Springer-Verlag.
13. Burian, Jan. (2004). Věda v bezvědomí. In: Kvasnička V., Kelemen J., (eds.), *Kognice a umělý život IV: 26.05.-30.05.2004*, Hradec nad Moravicí. Opava: Slezská univerzita, 2004. Dostupné na WWW: <http://eldar.cz/honza/articles/burian_vedomi_plusVarela.doc>.
14. Burian, Jan. (2005a). Kognice kontra Informace. In: Kelemen, J., Kvasnička V., Pospíchal J. (eds.), *Kognice a umělý život V: 30.5. – 2.6 2005*, Smolenice. Opava: Slezská univerzita v Opavě, 2005. Dostupné na WWW: <http://eldar.cz/honza/articles/burian_kognice_informace.doc>.
15. Burian, Jan. (2005b). Stumbling over substance: Why can't we agree about the nature of consciousness?. *Towards science of consciousness 2005: 17.8.-20.8. 2005*, Copenhagen. Copenhagen, 2005. Dostupné na WWW: <http://eldar.cz/honza/articles/Burian_TSC2005_abstract_final.doc>.
16. Burian, Jan. (2006a). Samoorganizace a kognice. In: Kelemen, J., Kvasnička V. (eds.), *Kognice a umělý život VI: 28.5. – 1.6 2006*, Třešť. Opava: Slezská univerzita v Opavě, 2006. Dostupné na WWW: <http://eldar.cz/honza/articles/burian_samoorganizae_kognice_final.doc>.
17. Burian, Jan. (2006b). Ethics of artificial consciousness. In MAGNANI, L. (ed), *Computing and Philosophy*. Pavia: Associated International Academic, 2006. ISBN 88-89659-02-5
18. Burian, J. (2006c). Perspektivy mozkové stimulace. In: Šíkl, R., Špok, D., Heller, D., Vobořil, D., Lukavský, J. (eds.), *Kognice 2006*. Praha: Psychologický ústav AV ČR, 2006.
19. Burian, Jan. (2007). Evoluce averze k riziku a nejistotě. In Kelemen, J., Kvasnička V. (eds.), *Kognice a umělý život*. Opava: Slezská univerzita v Opavě. 2007.
20. Burian, Jan. (2008a). Myšlení modelů. In Kvasnička Vladimír, Kelemen Jozef, Pospíchal Jiří (eds.), *Modely mysle*. Európa. 2008. ISBN: 978-80-89111-34-3.

21. Burian, Jan. (2008b). Multiagentní model transakčních nákladů na finančních trzích.
22. In Kelemen, J., Kvasnička V. (eds.), *Kognice a umělý život VIII*. Opava: Slezská univerzita v Opavě. 2008.
23. Burian, Jan. (2009a). Multiagentní modely sociálních organizací. In Petrů, M. (ed.), *Struny mysli*. Olomouc: Palackého univerzita, Olomouc. 2009.
24. Burian, Jan.(2009b).Meditace z hlediska neurověd. In Kelemen, J., Kvasnička V. (eds.), *Kognice a umělý život IX*. Opava: Slezská univerzita v Opavě. 2009.
25. Bondy. E. (1997). *Cybercomics*. Brno: Zvláštní vydání.
26. Cahlík, T. (2006). *Multiagentní přístupy v ekonomii*. Praha : Karolinum 2006.
27. Cools, S.B., C. Gershenson, and B. D'Hooghe (2006). *Self-organizing traffic lights: A realistic simulation*. Dostupné na WWW: < <http://uk.arxiv.org/abs/nlin.AO/0610040>>.
28. Corning, Peter A. (2002), The Re-Emergence of "Emergence: A Venerable Concept in Search of a Theory. *Complexity* 7(6): 18-30
29. Epstein, J. M. (2002). Modeling civil violence: An agent-based computational approach. *Proceedings of the National Academy of Science*. Vol. 99, Suppl. 3, May 14, 2002. Dostupné na WWW: <http://www.pnas.org/cgi/content/abstract/99/suppl_3/7243>.
30. Epstein, J. and Axtell, R. (1996). *Growing Artificial Societies: Social Science from the Bottom Up*. Washington, D.C.: Brookings Institution Press.
31. Ellsberg, D. (1961). Risk, Ambiguity, and the Savage Axioms. *Quarterly Journal of Economic*, 1961, no. 75, p. 643-669.
32. Fiala, P. Dlouhý, M. (2006). *Základy kvantitativní ekonomie a ekonomické analýzy*.
 Praha : Oeconomica.
33. Fox, J. (2010). *The R Commander: A Basic-Statistics GUI for R*. [online]. [cit. 1.5.2010]. Dostupné na WWW: <<http://socserv.mcmaster.ca/jfox/Misc/Rcmdr/>>.
34. Gardner, M. (1970). *Scientific American*. October, 1970.
35. Gigerenzer, Gerd; Selten, Reinhard (2002). *Bounded Rationality: The Adaptive Toolbox*. MIT Press.
36. Glimcher, P.W. Rustichiny, A. (2004). Neuroeconomics: The consilience of Brain and Decision. *Science*, 2004, vol. 306, is. 5695, p. 447-452.
37. J. Goldstein. (1999). Emergence as a Construct: History and Issues. *Emergence* 11: 1999, pp. 49-72.

38. Gonçalves, C. P. (2003). *Artificial Financial Market Model*. Dostupné na WWW: <[http://ccl.northwestern.edu/netlogo/models/community/Artificial Financial Market Model](http://ccl.northwestern.edu/netlogo/models/community/Artificial_Financial_Market_Model)>.
39. Hammond, R.A., Axelrod, R. (2005). The Evolution of Ethnocentrism. *The Journal of Conflict Resolution*. Beverly Hills: Dec 2006. Vol. 50, Iss. 6; pg. 926, 11 pgs.
40. Helbing, D., Farkas, I. & Vicsek, T. (2000). *Nature* (London) 407, 487–490.
41. Kauffman, S. (1995). *At Home in the Universe: The Search for the Laws of Self-Organization and Complexit*. Oxford University Press.
42. Hoffmann, R. (2000). Twenty Years on: The Evolution of Cooperation Revisited. *Journal of Artificial Societies and Social Simulation* vol. 3, no. 2. Dostupné na WWW:< <http://jasss.soc.surrey.ac.uk/3/2/forum/1.html>>.
43. Hsu, M. Bhatt, M. Adolphs, M. Tranel, D. Camerer, C.F. (2005). Neural Systems Responding to Degrees of Uncertainty in Human Decision-Making. *Science*, 2005, vol. 310, is. 5754, p. 1680-1683
44. Kubík, A. (2004). *Inteligentní agenty*. Grada.
45. Kvasnička, M. (2009) Simple Agent-Based Computational Model of Market Without Intermediation. *Mathematical Methods in Economics 2009*, p. 204–207.
46. Langton, C. G. (1990). Computation at the edge of chaos. *Physica D*, 42, 1990.
47. LeBaron, B. (2002). *Building the Santa Fe Artificial Stock Market*. Working Paper. Dostupné na WWW:< <http://people.brandeis.edu/~blebaron/wps/sfisum.pdf>>.
48. Macaš, M. Lhotská, L. (2009). Sociální vliv a optimalizace. In Petrů, M. (Ed.), *Struny mysli*. Ostrava : Montanex, 2009.
49. Macy, W.M., Willer, R. (2002). From factors to actors: Computational sociology and agent-based modeling. *Annual Review of Sociology*; 2002; 28, pg. 143
50. Maturana, H. Varela, F. (1980). Autopoiesis and Cognition: The Realization of the Living. *Boston Studies in the Philosophy of Science*, Vol. 42. D. Reidel Publishing Co. Dordecht.
51. Meyers, R. (Ed.) (2009). *Encyclopedia of Complexity and Systems Science*. Springer Science + Buisiness Media, LLC. pg. 200-222.
52. NetLogo. (2010). [online] [cit. 1.5.2010]. Dostupné na WWW: <<http://ccl.northwestern.edu/netlogo/>>.
53. Penttinen, J. (ed.), et al. (2005). *MORE TAXES! Promoting Strategies for Global Taxation*. ATTAC Finland. Dostupné na WWW: <<http://www.globalpolicy.org/soecon/glotax/currtax/2005/04moretaxes.pdf>>.

54. Popadinec, M. (2009). *Multiagentní modely finančních trhů – racionalita a sociální vazby*. Diplomová práce. Vysoká škola ekonomická, Praha.
55. Pospíchal, J. 2002. Evolucia neuvedomelej spoluprácie v drevorubačskej dileme. In: Kelemen, J., Kvasnička V. (eds.), *Kognice a umělý život II*: 13.5. – 16.5. 2002, Milovy. Opava: Slezská univerzita v Opavě, 2005.
56. Pospíchal, J. Kvasnička V. (2006). Rozhodovanie v sociálnej sieti. In: Kelemen, J., Kvasnička V. (eds.), *Kognice a umělý život VI*: 28.5. – 1.6 2006, Třešť. Opava: Slezská univerzita v Opavě, 2006.
57. Pospíchal, J. Kvasnička, V. (2005). In: Kelemen, J., Kvasnička V., Pospíchal J. (eds.), *Kognice a umělý život V*: 30.5. – 2.6 2005, Smolenice. Opava: Slezská univerzita v Opavě, 2005.
58. Rauch, J. (2002). Seeing Around Corners; *The Atlantic Monthly*; April 2002; Volume 289, No. 4; 35-48. Dostupné na WWW: <http://www.theatlantic.com/issues/2002/04/rauch.htm>
59. REPAST. (2010). [online]. [cit. 1.5.2010]. Dostupné na WWW: <http://repast.sourceforge.net>.
60. Robotomie. (2010). [online]. [cit. 1.5.2010]. *Robotomie, Netlogo*. Dostupné na WWW: <http://www.robotomie.cz/robodownload.php?q=netlogo>.
61. Paul Rendell (2005). [online] . *A Turing Machine in Conway's Game of Life*. [cit. 1.5.2010]. Dostupné na WWW: <http://rendell-attic.org/gol/tm.htm>.
62. Reynolds, C. (2001). *Boids*. Dostupné na WWW: <http://www.red3d.com/cwr/boids/>.
63. Railsback, s. (2006). Agent-based Simulation Platforms: Review and Development Recommendations. *SIMULATION*. Vol. 82, No. 9, 609-623.
64. Samuelson, W. Nordhaus, W. (1991). *Ekonomie*. Praha: Svoboda, 1991.
65. Schelling, T. (1978). *Micromotives and Macrobehavior*. New York: Norton.
66. Sensfuß, R. Ragwitz, M. Genoese, M. Möst, D. (2007). *Agent-Based Simulation of Electricity Markets: A Literature Review Working Paper Sustainability and Innovation*. No. S 5/2007, Fraunhofer Institute Systems and Innovation Research. Dostupné na WWW: <http://www.econ.iastate.edu/tesfatsi/ACEElectricSurvey.SensfussEtAl.2007.pdf>.
67. Shalizi, C. R. (2001). *Causal Architecture, Complexity and Self-Organization in Time Series and Cellular Automata*. Dissertation thesis. Dostupné na WWW: <http://www.cscs.umich.edu/~crshalizi/thesis/>.

68. Shleifer, A. (2000). *Inefficient Markets, An Introduction to Behavioral Finance*. Oxford University Press.
69. Sornette, D. (2003). *Critical Market Crashes*. Dostupné na WWW: <<http://arxiv.org/abs/cond-mat/0301543>>.
70. Soukupová J. Hořejší B. Macáková L. Soukup J. (2002). *Mikroekonomie*. Management Press 2002.
71. Sun, R. (2006). *Cognition and Multi-Agent Interaction: From Cognitive Modeling to Social Simulation*. Cambridge University Press.
72. Sekerka, R. (2009). *Modelování oceňování projektů*. Diplomová práce. VŠE, Praha.
73. Tesfatsion, L. (2010). [online]. *Agent-Based Computational Economics*. [cit. 1.5.2010]. Dostupné na WWW:<<http://econ2.econ.iastate.edu/tesfatsi/ace.htm>>.
74. Tononi, G. Sporns, O. and Edelman, G. (1996). A complexity measure for selective matching of signals by the brain. *Proc. Natl. Acad. Sci. USA*. 1996, Apr., Vol. 93: 3422-3427.
75. Wilensky, U. (1997a). *NetLogo Fire model*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. Dostupné na WWW: <<http://ccl.northwestern.edu/netlogo/models/Fire>>.
76. Wilensky, U. (1997b). *NetLogo AIDS model*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. Dostupné na WWW: <<http://ccl.northwestern.edu/netlogo/models/AIDS>>.
77. Wilensky, U. (1997c). *NetLogo Ants model*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. Dostupné na WWW: <<http://ccl.northwestern.edu/netlogo/models/Ants>>.
78. Wilensky, U. (1997). *NetLogo Segregation model*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. Dostupné na WWW: <<http://ccl.northwestern.edu/netlogo/models/Segregation>>.
79. Wilensky, U. (2002). *NetLogo PD Basic Evolutionary model*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. Dostupné na WWW: <<http://ccl.northwestern.edu/netlogo/models/PDBasicEvolutionary>>.
80. Wilensky, U. (2003). *NetLogo Traffic Grid model*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. Dostupné na WWW: <<http://ccl.northwestern.edu/netlogo/models/TrafficGrid>>.
81. Wilensky, U. (2003a). *NetLogo Ethnocentrism model*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. Dostupné na WWW:<<http://ccl.northwestern.edu/netlogo/models/Ethnocentrism>>.

82. Wilensky, U. (2005). *NetLogo Flocking 3D Alternate model*. Center for Connected Learning and Computer-Based Modeling, Northwestern University, Evanston, IL. Dostupné na WWW:
<<http://ccl.northwestern.edu/netlogo/models/Flocking3DAlternate>>.
83. Wolfram, S. *A New Kind of Science*. Wolfram Media. 2002.
84. Zajac, J. Multiagentový prístup a simulácie ekonomiky. (2004) In: Kvasnička V., Kelemen J., (eds.), *Kognice a umělý život IV*: 26.05.-30.05.2004, Hradec nad Moravicí. Opava: Slezská univerzita, 2004.

10. Příloha – Popis přiloženého DVD

Adresář/soubor	Obsah
burian_rACE_final.pdf	Tato práce ve formátu PDF
financial_market\	Model transakčních nákladů na finančním trhu a výstupní data modelu
evolution_aversion\	Model evoluce averze k riziku a nejistotě a výstupní data modelu
monopson\	Model monopsonu na trhu práce a výstupní data modelu
illustration_models\	Adresář obsahuje níže uvedené ilustrační modely.
ethnocentrism_complexity	Model evoluce etnocentrického chování rozšířený o měření strukturální complexity
prisoners_dillema_parallel\	Paralelní a sekvenční verzi iterace modelu opakovaného vězňova dilematu ve 2D mřížce
segregation_more_ethnics_and_minorities\	Model rasové segregace rozšířený o více etnik a minority; výstupní data modelu
two_anthills\	Model „souboje“ dvou mravenišť