

Modelování a simulace komplexních systémů

Radek Pelánek*

2011

*Upozornění: Nabyvatelem výhradní licence ke knize je Masarykova univerzita. Podle smlouvy s nabyvatelem licence může být elektronická verze knihy zveřejněna pouze na webu radekpelanek.cz.

Obsah

Předmluva	5
Část I Obecné principy	7
1 Úvod	9
1.1 O tématu	10
1.2 Proč se modelováním zabývat?	11
1.3 O knize	14
2 Komplexní systémy	17
2.1 Jednoduché a složité	18
2.2 Charakteristiky komplexních systémů	20
2.3 Studium komplexních systémů	23
2.4 Shrnutí	25
3 Uvažování o systémech	27
3.1 Intuitivní myšlení	28
3.2 Systémové myšlení	32
3.3 Induktivní a deduktivní myšlení	34
3.4 Decentralizované myšlení	35
3.5 Shrnutí	36
4 Zpětná vazba	37
4.1 Základní zpětné vazby	38
4.2 Kombinace zpětných vazeb	41
4.3 Shrnutí	42
5 Modelování a simulace	43
5.1 Základní myšlenky o modelování	44
5.2 Cíle modelování a simulace	45
5.3 Typy modelů	47
5.4 Specifika výpočetních modelů	48

5.5	Fáze modelování	50
5.6	Shrnutí	54
Část II Metody modelování a simulace		57
6	Matematické modelování a systémová dynamika	59
6.1	Matematické modelování pomocí rovnic	60
6.2	Systémová dynamika	65
6.3	Základní vzory chování	68
6.4	Shrnutí	70
7	Buněčné automaty a modelování založené na agentech	71
7.1	Buněčné automaty	72
7.2	Příklady buněčných automatů	75
7.3	Modelování založené na agentech	78
7.4	Příklady modelů založených na agentech	80
7.5	Shrnutí	81
8	Modelování myšlení a vývoje	83
8.1	Teorie her a racionální uvažování	84
8.2	Modelování induktivního myšlení	86
8.3	Simulovaná evoluce	91
8.4	Shrnutí	94
9	Komplexní sítě	95
9.1	Úvodní poznámky	96
9.2	Vlastnosti komplexních sítí	97
9.3	Modely komplexních sítí	100
9.4	Procesy na sítích	102
9.5	Shrnutí	104
10	Metody analýzy modelů	105
10.1	Úvodní poznámky	106
10.2	Verifikace a validace modelu	107
10.3	Zobrazení chování modelu	108
10.4	Analýza citlivosti	113
10.5	Experimenty s modelem	116
10.6	Shrnutí	117
Část III Případové studie		119
11	Epidemie	121
11.1	Základní koncepty	122

11.2	Jednoduché modely SIR epidemie	124
11.3	Rozšíření základních modelů	127
11.4	Příklady studií a nástrojů	130
11.5	Shrnutí	131
12	Základní principy života	133
12.1	Sebe-reprodukce a vznik života	134
12.2	Evoluce	138
12.3	Samo-organizace	140
12.4	Homeostáza	145
12.5	Shrnutí	148
13	Modelování sociálních a ekonomických systémů	149
13.1	Pozitivní zpětná vazba v ekonomii	150
13.2	Modelování trhu	153
13.3	Umělé společnosti	155
13.4	Shrnutí	159
14	Spolupráce a soutěžení	161
14.1	Dilema vězně	162
14.2	Turnaje počítačových strategií	164
14.3	Modelování vzniku norem	169
14.4	Altruismus	171
14.5	Shrnutí	173
15	Meze růstu	175
15.1	Úvodní poznámky	175
15.2	Model World3	177
15.3	Analýza modelu	179
15.4	Závěry a souvislosti	180
15.5	Shrnutí	182
16	Příklady aplikací modelování	185
16.1	Modelování počasí a klimatu	186
16.2	Modelování dopravy	189
16.3	Systémová biologie	192
16.4	Shrnutí	194
17	Pákové body	195
17.1	Hierarchie pákových bodů	196
17.2	Paretův princip	199
17.3	Příklady	200
17.4	Shrnutí	202
	Závěr	203

Literatura	205
A Slovníček pojmů	211
B Přehled modelů	215
C Softwarové nástroje	217
D Náměty na cvičení a projekty	221
D.1 Epidemie	221
D.2 Populační dynamika	223
D.3 Obecné náměty	225
E Návodné otázky	229

Předmluva

Mysl není nádoba, kterou je potřeba naplnit, ale oheň, který je potřeba zapálit. (Plutarchos)

Vše, co můžeme udělat, je lidi inspirovat. (Instruktoři Brno)

Hlavním cílem této knihy není předat čtenářům konkrétní informace, ale alespoň trochu změnit jejich pohled na svět. Za klíčový považuji nikoliv konkrétní obsah knihy, ale její styl. Tento styl je do velké míry ovlivněn mým napojením na organizaci Instruktoři Brno.

Instruktoři Brno pořádají zážitkové akce pro dospělé – většinou pro lidi nadprůměrně inteligentní, schopné a samostatné. Akce Instruktorů Brno a celkové fungování této organizace vychází z přesvědčení, že takové lidi není možné ani žádoucí přímo vychovávat, vodit je za ruku a říkat jim, co mají dělat, ale že nejúčinnější je lidi inspirovat, ukázat jim možné cesty a nechat je vybrat si, co je zaujme a pro co se rozhodnou. Schopný člověk, když se pro něco nadchne, toho dokáže velmi mnoho a nepotřebuje, aby jej někdo vodil za ruku.

Podobný přístup – především inspirovat, nikoliv přímo vychovávat a vyučovat – se snažím používat i při výuce a také v této knize. Není klíčové, aby si studenti (čtenáři) odnesli konkrétní vědomosti, ale aby měli možnost vidět nové a zajímavé obzory, o kterých dříve nevěděli, a aby měli dostatečný odrazový můstek pustit se do vlastního prozkoumávání těch obzorů, které je zaujmou.

Po obsahové stránce sahají prameny knihy do dob mého studia na Fakultě informatiky Masarykovy univerzity, kdy jsem ze zájmu procházel různé knihy a texty o komplexních systémech, chaosu, fraktálech, komplexitě a podobných tématech. Jako doktorský student jsem se později dostal i na letní školu, která se zabývala těmito tématy. Když jsem se pln nadšení vrátil, navrhl jsem, že by se na naší fakultě mohl vyučovat předmět o komplexních systémech. Mé nadšení sice nebylo úplně sdíleno, ale shodou okolností zrovna odešel přednášející předmětu Simulace a bylo mi řečeno, že nový předmět by být mohl, kdyby se mi podařilo zkombinovat témata komplexních systémů a simulace. Zpětně považuji tento vývoj za velmi šťastný – sice jsem se vzdálil od zajímavých témat, jako je chaos a fraktály, ale důraz na modelování a simulaci přidal tématu na důležitosti a uspokojil moji potřebu alespoň občas trochu „zachraňovat svět“.

Kniha tedy do velké míry vychází z mé výuky, konkrétně z přednášek „Modelování a simulace“ a ze „Semináře o komplexních systémech“. Protože se snažím o vedení výuky v duchu výše uvedených citátů, vyžadují po studentech samostatnou aktivitu – vytváření vlastních modelů, tvorbu projektů, psaní stručných článků a čtenářských deníků. Kromě toho, že věřím v pedagogickou účinnost takových aktivit, poskytují mi výtvořky studentů novou inspiraci na zdroje a také zpětnou vazbu o tom, co lidi zajímá. Cenným materiálem jsou pro mne také špatné modely, které studenti občas v rámci projektů vytvoří, protože nad špatným modelem si toho mnohdy uvědomíme o metodologických otázkách více než nad dobrým. V literatuře však najdeme jen příklady dobrých modelů a chyby ve svých vlastních modelech je velmi těžké vidět (ať už se jedná o modely mentální nebo počítačové). První poděkování tedy patří všem studentům, kteří v letech 2006–2010 prošli mými kurzy a kteří tak, vesměs nevědomky, přispěli ke vzniku a obsahu této knihy.

Poděkování dále patří všem, kdo svými připomínkami k pracovním verzím přispěli k finální podobě knihy: Janu Strejčkovi, Radanu Květovi, Robertu Greplovi, Pavlu Krčálovi, Ondřeji Krčálovi a Davidu Šafránkovi. Speciální dík patří Cyrilu Bromovi za jeho důkladný a konstruktivní posudek. Děkuji také Aleně Mizerové, Radce Vyskočilové a Evě Strnadové z Nakladatelství Masarykovy univerzity za spolupráci při finálních úpravách knihy.

Konečně velký dík patří mojí ženě Barče, která mě v průběhu přípravy knihy morálně podporovala, trpělivě reagovala na časté prosby „mohla by sis přečíst tohle a říct mi, jak ti to připadá“ a měla řadu připomínek a návrhů.

Radek Pelánek

Část I

Obecné principy

Segregace, 1971. Thomas Schelling popsal velice jednoduchý a abstraktní model, který ukazuje, jak může dojít k vysokému stupni segregace mezi obyvateli různé barvy pleti i v případě, že jednotlivci jsou tolerantní. Schelling použil k simulaci svého modelu mince rozmístěné na papíře. Přístup, který svým modelem nastínil, se však o 20 let později stal základem „modelování s agenty“, při kterém se simulace provádí na výkonných počítačích.

Meze růstu, 1972. Jak bude vypadat interakce rostoucí globální ekonomiky a limitů planety? Čtveřice vědeckých pracovníků se pokusila nastínit odpověď na tuto otázku s využitím počítačového modelu World3. Kniha založená na analýzách tohoto modelu se stala světovým bestsellerem a výrazně ovlivnila rodící se environmentální hnutí.

Evoluce spolupráce, 1984. Robert Axelrod uspořádal turnaje počítačových strategií ve hře Dilema vězně, což je modelová situace popisující rozhodování mezi spoluprací a soutěží. Výsledky počítačových simulací ukázaly, jak se může spolupráce vyvinout i ve skupině egoistických jedinců. Kniha ovlivnila tisíce čtenářů v tom, jak přemýšlí o spolupráci a soutěžení, a podnítila velké množství dalšího výzkumu především v humanitních vědách.

Umělé hejno, 1986. Craig Reynolds představil model umělého hejna. Model obsahuje umělé tvory, kteří se pohybují po prostoru a dodržují tři jednoduchá pravidla pohybu. I přes jednoduchost pravidel připomíná výsledná simulace chování skutečného ptačího hejna. Reynoldsova pravidla se stala základem mnoha dalších modelů, které se využívají například v počítačové grafice.

Epidemie nemoci šílených krav, 2001. Když v roce 2001 zasáhla Velkou Británii epidemie nemoci BSE. V rámci ochrany proti nemoci byla přijata drastická preventivní opatření, která spočívala mimo jiné ve vybití zdravých stád nacházejících se v okolí postižených farem. Tato opatření byla přijata mimo jiné i na základě analýz, které byly provedeny pomocí výpočetních modelů šíření epidemie.

Hadž, 2005. Miliony poutníků se každoročně vydávají do Mekky, aby vykonaly posvátnou pouť, jeden z pěti pilířů islámu. Při Hadži putují společně velké davy lidí

a často dochází ke katastrofám, při kterých zahynou vlivem nehod a ušlapání až stovky lidí. Uspořádání mostu Jamarat, jednoho z kritických míst trasy, bylo v roce 2005 pozměněno na základě výsledků simulací.

Zprávy IPCC, 2007. Mezinárodní panel pro klimatické změny (IPCC) obdržel Nobelovu cenu za svůj podíl na šíření vědomostí o klimatických změnách. IPCC tohoto cíle dosahuje především pomocí vydávání rozsáhlých souhrnných zpráv (v roce 2007 vyšla čtvrtá zpráva). Zprávy IPCC jsou do velké míry založeny na výsledcích rozsáhlých modelů klimatu.

Co mají tyto příběhy společného? Vypráví o komplexních systémech, tedy o systémech, které se skládají z mnoha složitě propletených částí a jež nedokážeme naprosto přesně uchopit. Ve všech příbězích se také využívá modelování a simulace. Příběhy tak uvádí konkrétní příklady toho, o čem je celá tato kniha – o modelování komplexních systémů a o tom, k čemu všemu nám to může posloužit.

1 Úvod

S: Podívej, pořídil jsem si novou knihu.

M: Nechápu, proč si v dnešní době ještě kupuješ knihy. Všechno najdeš na internetu.

S: To je ta dnešní mládež, všechno by hledala na internetu. Jenže abys něco našel na internetu, nejdřív potřebuješ vědět, co vlastně máš hledat. Navíc intelektuální stravování na internetu se podobá stravování ve fast-foodu: rychle, levně, nekvalitně a většinou si k tomu dáš nezdravý zákusek, který jsi původně vůbec nechtěl.

M: Přestaň mě poučovat a raději mi řekni, o čem je ta tvoje nová kniha.

S: Jmenuje se „Modelování a simulace komplexních systémů“. Modely určitě znáš: třeba mapa jako model terénu nebo autíčko na hraní jako model reálného auta. Tady v té knize se mluví o výpočetních modelech. Představ si třeba počítačový model pohybu koulí na kulečnickovém stole – model tvoří rovnice popisující pohyb koulí, simulací tohoto modelu dostáváš obrázek na monitoru, který vizualizuje pohyb koulí.

M: A co je na tom komplexního?

S: Správný postřeh. Kdybys mě nechal domluvit, hned bych se k tomu dostal. Kulečnickový stůl je jednoduchý systém, podobně jako třeba soustava kladek. Tady v té knize ale jde o komplexní systémy, což jsou systémy, které se skládají z mnoha vzájemně provázaných částí – například počasí, mozek nebo tvůj oblíbený internet.

M: A proč sis pořídil zrovna tuhle knihu? Co tě na tom láká?

S: Já mám takové jednoduché základní kritérium, jestli se něčím zabývat: mělo by to být současně důležité, aktuální a zajímavé. Tak především člověk by se měl snažit v životě dělat něco důležitého. Samotná důležitost ale nestačí. Studium způsobů šíření moru bylo ve středověku jistě velmi důležité, ale dneska tím svět nezachráníš. Takže je potřeba, aby téma bylo i aktuální. Krom toho je potřeba, aby mi téma přišlo zajímavé. Jinak za chvíli ztratím motivaci a stejně nic moc nevymyslím.

M: Kritérium se mi líbí. A tohle téma jej splňuje?

S: Já myslím, že určitě. Až do nedávna se lidé snažili rozkládat problémy na dílčí pod-systémy a řešit tyto dílčí jednoduché systémy. Mnohé z dnešních problémů jsou však ze své podstaty komplexní a nejdou rozložit na podproblémy – změny klimatu, celosvětové

epidemie, globální ekonomika. Až do nedávna takové složité problémy ani přímo moc řešit nešly, ale teď máme k dispozici počítače, díky kterým můžeme dělat spoustu nových věcí – třeba simulace. Takže je to důležité a aktuální. Navíc je to rozhodně i zajímavé. Kdybys nevěřil, můžu ti ukázat pár konkrétních simulací.

M: Dobrá, dobrá, docela jsi mě nalákal, jenže teď zrovna nemám čas. Musím psát seminární práci o králících. Náš učitel je navíc nějak podezřele moderní a chce po nás, aby práce byla interdisciplinární a aby obsahovala interaktivní prvky. Tak nevím, co si s tím počnu. . .

S: Možná by se ti mohlo hodit třeba právě modelování.

M: . . . ale internet mě určitě zachrání.

1.1 O tématu

Téma této knihy shrnuje její název: „Modelování a simulace komplexních systémů“. Pojmy uvedené v názvu se však používají v mnoha různých významech, a proto raději hned na začátku upřesníme, v jakém významu jsou používány v této knize.

Modelování a simulace

S modelováním se každý z nás setkává již od dětství, kdy jsme se zaujetím simulovali srážku dvou aut nebo život v plyšovém pralesi. V této knize se však nebudeme zabývat takovýmito fyzickými modely, ale zaměříme se na modely výpočetní, které definují pravidla proveditelná na počítači. Jak uvidíme, provádění simulací na počítači je často téměř tak dobrodružné jako srážky autíček. Navíc využití počítačových modelů nám velmi rozšiřuje možnosti. Málokdo z nás má tak bohaté rodiče, aby mu pořídili malou planetku, kterou by mohl ostřelovat asteroidy nebo si na ní zkoušet důsledky pomalého ohřívání atmosféry.

Aby si čtenář udělal představu o tom, čím se kniha zabývá, uvedeme jednoduchý příklad – populační dynamika králíků a lišek. Nejjednodušší model můžeme sestavit pomocí matematických rovnic, které popisují vzájemnou závislost celkového počtu králíků a lišek. Rovnice například říká, že když je hodně králíků a málo lišek, tak bude lišek výrazně přibývat (malá konkurence, hodně potravy). Rovnice následně řešíme pomocí počítače a výsledkem řešení je graf, který udává například vývoj celkového počtu králíků v čase.

Další možností je použít model s agenty. Agenti jsou jednotlivá zvířata pohybující se po vymezeném prostoru. Králíci žerou trávu, lišky honí a žerou králíky, všichni se množí a umírají podle svých energetických zisků a stárí. Simulace modelu je grafická – vidíme pohyb jednotlivých tvorů. Výsledky simulace můžeme samozřejmě také číselně zpracovat a vyjádřit třeba opět grafem.

Můžeme vyrobit také evoluční model, ve kterém jedince reprezentujeme řetězcem „genů“ a simulujeme vzájemnou koevoluci králíků a lišek, např. vývoj dlouhých uší králíků jako evoluční přízpůsobení v prostředí, ve kterém lišky loví neopatrné králíky.

Výsledky simulace mohou být například statistiky o průměrném zastoupení genů a neúspěšnějších jedincích v jednotlivých generacích.

K příkladu s králíky a liškami se detailněji vrátíme v druhé části knihy. Zde pro ukázkou uvádíme ještě obr. 1.1, který ukazuje, jak mohou vypadat výstupy simulace výpočetního modelu (nejen s králíky). Všechny uvedené příklady jsou blíže rozebrány v dalších kapitolách.

Komplexní systémy

Komplexní systémy jsou systémy sestávající z mnoha částí, které jsou spolu komplikovaným způsobem provázané a složitě se vzájemně ovlivňují. Příklady komplexních systémů jsou třeba mraveniště, mozek, firma, internet nebo počítač.

Komplexní systémy jsou všude kolem nás. Přemýšlení o těchto systémech však stále spadá spíše do oblasti filozofie, exaktní vědy se zabývají systémy relativně jednoduchými (k významu slov *komplexní* a *jednoduchý* se podrobněji dostaneme v další kapitole). Čím to je? Jeden z Murphyho zákonů říká: „Když máte v ruce kladivo, všechno na světě vám připadá jako hřebík.“ Sofistikovaněji rozebírá tento princip Thomas Kuhn ve své známé knize o paradigmatech (Struktura vědeckých revolucí). Lidé, vědce nevyjímaje, mají tendenci vidět jen problémy, jež jsou schopni pochopit a řešit pomocí nástrojů, které již mají k dispozici.


Hlavním nástrojem, jež si vědci během posledních 2000 let oblíbili, je matematika. Problém zachytíme pomocí matematických rovnic a tyto rovnice analyzujeme. Uvedený nástroj je pro mnoho problémů velice efektivní, ovšem jeho potenciál je omezený – dokážeme analyzovat pouze rovnice, které mají relativně omezený počet proměnných. Tento efektivní nástroj (kladivo) tedy do velké míry určoval problémy, které vědci řeší, případně jak se na problémy dívají (jako na hřebíky).

S příchodem počítačů se otevřely nové možnosti, které jednak umožňují lepší práci s klasickými nástroji (počítačová analýza rovnic) a jednak zcela nové přístupy, jako je třeba právě výpočetní modelování a simulace. Tyto přístupy umožňují analyzovat výrazně složitější systémy než klasický matematický aparát. A tak vědci najednou zjišťují, že kromě problémů, které dlouhou dobu studovali, tu jsou celé oblasti, jichž si nikdo pořádně nevšiml.


Během posledních pár let se objevuje řada nových oborů, např. generativní sociologie, výpočetní ekonomie, systémová biologie, věda sítí, bioinformatika. Všechny nabízejí nový pohled na tradiční disciplíny pomocí počítačových simulací a analýz. Tyto obory mají také mnoho společného – hledání těchto společných prvků bývá označováno jako věda komplexních systémů.

1.2 Proč se modelováním zabývat?


V současnosti stojíme před mnoha problémy, které jsou vzájemně složitě propojeny a nelze je jednoduše zařadit do žádné tradiční vědecké disciplíny: změny klimatu, znečištění životního prostředí, náboženský a národnostní extremismus, rostoucí sociální nerovnosti, epidemie AIDS, ilegální přistěhovalectví, docházející neobnovitelné




Dynamika populace králíků a lišek




Sumární výstupy z klimatických modelů




Sebe-reprodukcující se cykly



Mravenci: sběr potravy



Šíření epidemie v sociální síti



Umělé hejno

Obr. 1.1: Příklady výstupů simulací.

zdroje. Tyto problémy nelze řešit redukcionisticky rozsekáním na dílčí části a detailní analýzou izolovaných podproblémů – nemůžeme studovat změny klimatu či společnosti v Evropě, aniž bychom vzali v potaz ekonomický růst Číny či demografii Afriky. Abychom mohli problémy tohoto typu řešit, potřebujeme se učit přemýšlet o komplexních systémech.

Modelování a simulace jsou velmi užitečné nástroje, které nám k tomu mohou dopomoci. Díky modelům můžeme dělat předpovědi, odhadovat dopad různých zásahů do systémů a lépe plánovat naše akce. Kromě těchto konkrétních výsledků jsou však modely velmi důležité i na mentální úrovni – pouhá práce s modely výrazně ovlivňuje náš způsob myšlení a nahlížení na svět. Modely nás nutí jasně formulovat naše mlhavé představy. Simulace nás konfrontují s důsledky těchto představ. Modelování a simulace také umožňují sdílení myšlenek a tolik potřebné předávání informací mezi odborníky z různých oborů.

Modelování a simulaci používají lidé již dlouho, dříve se však používaly především v technických oborech při řešení relativně jednoduchých problémů (např. návrh součástí, zkoumání statiky mostu). Příchod výpočetní techniky však umožnil rozšíření výzkumných obzorů dvěma způsoby: máme k dispozici daleko víc dat a můžeme je daleko lépe zpracovávat a modelovat. Uvažme takové zákony gravitace. Na jejich objevení musí být člověk velmi chytrý, ale počítače k tomu nepotřebuje: potřebná data si naměří ručně, zapíše do deníku, výsledné rovnice obsahují jen pár proměnných, a tak je lze zvládnout řešit ručně.

Jenže co takové chování lidské společnosti, hejna ptáků nebo počasí? Tyto systémy je potřeba zkoumat v celku – nelze je rozsekát na části a ty samostatně analyzovat. Popsat chování celku je ovšem zapeklitě komplikované, nestačí nám k tomu pár pozorování a rovnice s několika proměnnými. Ke zkoumání těchto systémů jsou počítače nezbytné, a to ze dvou důvodů. Za prvé můžeme pomocí počítačů ve velkém sbírat a zpracovávat data, např. data o vztazích mezi lidmi na základě telefonátů a e-mailů, data o pohybu ptáků s použitím GPS technologie nebo data o počasí z propojené sítě meteorologických stanic rozestých po celém světě. Za druhé pak můžeme vytvářet rozsáhlé modely těchto systémů.

Počítače, které jsou pro tyto účely dostatečně výkonné a současně dostupné, aby se daly používat pro zkoumání ve velkém, mají lidé k dispozici teprve od konce 20. století. Výzkum v této oblasti je tedy teprve v začátcích – značná část technik a příkladů, kterými se budeme zabývat, pochází z období posledních dvaceti let.

Simulace výpočetních modelů jsou však nejen důležité a aktuální, ale také zajímavé, především svými vizuálními výstupy. Přinejmenším dostáváme grafy, které znázorňují chování systému v čase. Často se nám však přímo před očima odehrává vývoj modelovaného systému – můžeme sledovat postup hurikánu, mravence sbírající potravu, soutěžící agenty, vznik zácpy na silnici nebo vývoj pohybového aparátu imaginárního organismu. Vizuální výstupy jsou pochopitelné i pro laiky. Dobře zpracovaná simulace dává smysl a přináší pochopení i bez detailní znalosti technik, které model využívá.

Dobrý model komplexního systému může přinést překvapivé výsledky, ba i nabourat naše zaběhané stereotypy. Ukázat, že i jednoduchá pravidla mohou vést k velmi

složitému chování, náhoda může být základem řádu, hejno nepotřebuje vůdce, segregace může vzniknout i při vysoké toleranci jednotlivců nebo že i pro soutěživé egoisty může být nejvýhodnější spolupráce. Ani dobrý model sám o sobě svět nezmění. Model však může změnit náš pohled na svět. Zbytek už je na nás.

1.3 O knize

Pokud předchozí řádky čtenáře pro modelování navnadili, je načase prozradit, co nabízí tato kniha.

Základní koncepce

Většina knih o modelování rozebírá detailně jeden modelovací přístup, případně se zaměřuje na jednu aplikační oblast. V této knize přistupujeme k tématu jinak – jde o přehled různých přístupů ilustrovaný na příkladech z mnoha oblastí. V žádném tématu nezacházíme do úplných detailů, spíše se snažíme ukázat souvislosti. Účelem knihy je shromáždit zajímavé myšlenky, navnadit a inspirovat. Detaily může čtenář dohledat v uvedených zdrojích.

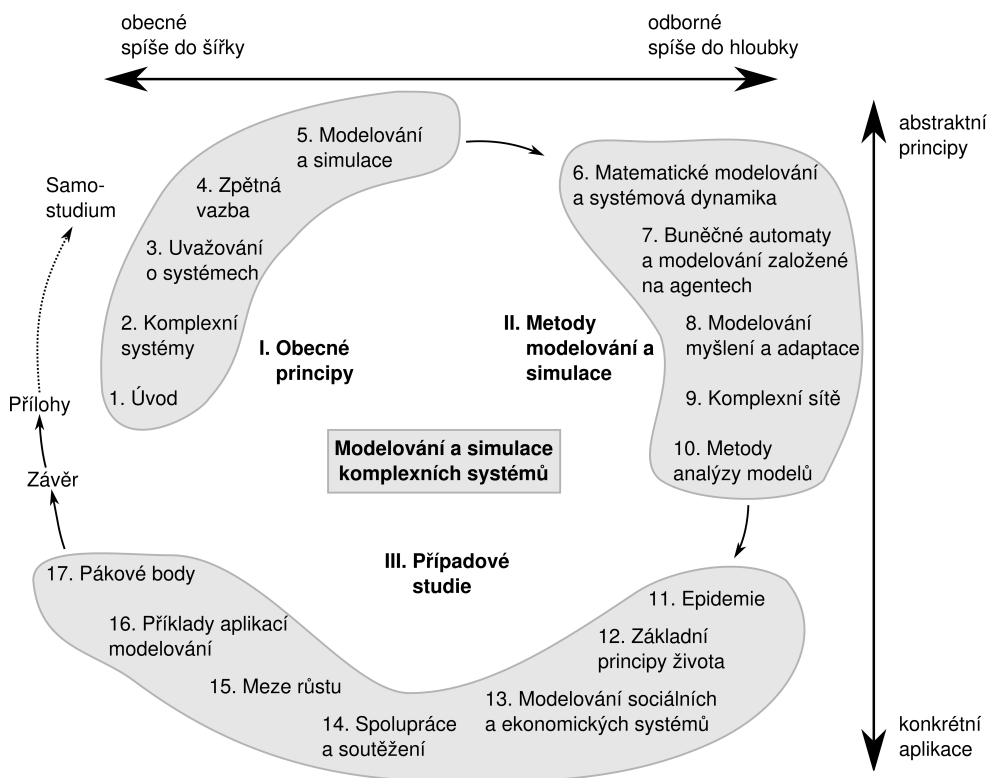
Proč tento přístup? Stejně jako ve většině jiných oblastí lidského činnosti ani v modelování neexistuje žádná „stříbrná kulka“, nástroj, který by byl opravdu univerzální a vždy fungoval. Každý modelovací přístup má svoje výhody a nevýhody, každý se hodí na jiný typ problémů. Vyplatí se znát pestrou paletu přístupů a být schopen pro konkrétní aplikaci vybrat ten vhodný. Doučit se potřebné detaily už není takový problém.

Klademe také důraz na použití příkladů – často místo detailního rozebírání technických a metodických aspektů volíme ilustraci na příkladu. Příklady jsou daleko čitelnější a zábavnější, čtenář z nich často pochopí základní principy lépe než z abstraktních úvah. I pro vlastní modelování, stejně jako pro mnoho jiných činností, je lepší imitovat konkrétní dobré postupy než snažit se dodržovat obecné metodické rady.

Uspořádání knihy

Celkové uspořádání knihy naznačuje obr. 1.2. Výklad začíná obecnými principy, následuje odbornější úvod do modelovacích technik a rozbor případových studií. Případové studie nejdříve popisujeme po technické stránce a na konci se opět vracíme k obecnému, netechnickému stylu. Postup studia by tak měl tvořit kružnici, nebo spíše spirálu – po dočtení knihy by čtenář měl být schopen absolvovat další „kolečka“ samostudiem.

Knihy je rozdělena do tří částí. První část podávající úvod do oblasti studia je napsána vyloženě populárně. Vysvětluje obecné pojmy a popisuje základní metodické principy, které jsou společné různým modelovacím přístupům. Příklady v této části jsou popsány pouze slovně a neformálně.



Obr. 1.2: Struktura knihy.

Druhá část je techničtější, obsahuje přehled modelovacích přístupů a technik použitelných pro modelování komplexních systémů. Techniky stručně popisujeme a ilustrujeme na jednoduchých příkladech. Pro možnost srovnání a lepší pochopení v celé části používáme především příklady z oblasti populační dynamiky.

Třetí část obsahuje konkrétní aplikace technik popsaných v druhé části. V rámci těchto studií se většinou kombinuje několik technik popsaných v druhé části textu, případně se tyto techniky dále rozvíjejí. Třetí část knihy slouží k lepšímu pochopení technik, k předvedení dobrých modelů, které dokáží měnit náš pohled na svět, a také k získání realistických představ o modelech komplexních systémů.

Aby čtenář opravdu pronikl do modelování, nestačí jen číst, je třeba se činit a samostatně si modelování vyzkoušet. V přílohách je uveden seznam rámcových námětů na cvičení a samostatné projekty a také tipy na nástroje, které je možné použít. V hlavním textu rozebíráme pouze obecné principy, konkrétní nástroje a programy – což je informace, která rychle zastarává – uvádíme pouze v příloze.

Uspořádání kapitol

*„Co je do knížky, když v ní nejsou žádné obrázky a nic se tam nepovídá,“
řekla si Alenka. (L. Carrol)*

Pro lepší pochopení obsahuje každá kapitola kromě vlastního výkladu také úvodní rozhovor a závěrečné shrnutí. Důležité myšlenky jsou tedy v knize sděleny nejméně třikrát (rozhovor, vlastní kapitola, shrnutí), pokaždé však jiným způsobem.

Rozhovory na sebe rámcově navazují, takže pro získání obecné představy o obsahu knihy si lze nejprve přečíst všechny rozhovory. Rozhovory vedou dva bratři pojmenovaní iniciálami M a S. M je mladší bratr, zvidavý středoškolák, který zrovna píše seminární práci o králících. S je starší bratr, vysokoškolák, který se zajímá o modelování a simulaci komplexních systémů.

Souvislosti a zdroje

Vzhledem k přehledovému charakteru knihy klademe důraz na souvislosti. Upozornění na souvislosti, které je typograficky odlišeno od běžného textu, informuje o zdrojích, ze kterých výklad čerpá a v nichž lze najít podrobnější informace, a také upozorňuje na související části knihy.

Mnohé partie knihy čerpají z velkého množství vzájemně se překrývajících zdrojů. V těchto případech je vždy k jedné delší partii uveden samostatný blok „souvislostí“, který stručně komentuje dostupnou literaturu k danému tématu. Vzhledem k učebnicovému a přehledovému charakteru této knihy uvádíme primárně zdroje, jež jsou relativně dostupné a přístupně zpracované, a nikoliv původní vědecké studie zabývající se daným tématem. V seznamu literatury jsou nejzajímavější zdroje okomentovány, aby čtenář snáze našel zdroje, které jsou pro něj zajímavé.

V knize se používá české názvosloví, nicméně drtivá většina zdrojů je psána anglicky a mnohé pojmy nemají ustálené české ekvivalenty. Proto je v příloze uveden slovníček.

2 Komplexní systémy

S: Tak co tvoje seminární práce o králících?

M: Hledal jsem na internetu a mám spoustu zajímavých podnětů. Zjistil jsem třeba, že králíci často vystupují v mytologii. Například podle korejských mýtů králíci obývají Měsíc a vyrábějí tam koláčky. Ale třeba o králíčím mozku jsem toho moc nenašel, a to je škoda, protože by mě zajímalo, co se honí králíkovi hlavou. Jak jsem o tom přemýšlel, tak mě napadlo – dokážeme dopravit člověka statisíce kilometrů vzduchoprázdnem až na Měsíc, abychom ověřili, zda tam opravdu králíci pečou koláčky, ale přitom pořádně nerozumíme rozdíl mezi naším a králíčím mozkiem. Nepřijde ti to zvláštní?

S: To je jasné. Dostat člověka na Měsíc je náročný úkol, ale dá se rozložit na sérii dílčích úkolů, které jdou řešit samostatně. Kdežto fungování mozku nemůžeš rozdělit na části a ty studovat samostatně. Mozek je komplexní systém a pochopit komplexní systém je daleko náročnější.

M: Myslíš si, že použiješ odborný termín, já se zaleknu a ty se vyvlečeš z odpovědi? Kdepak. Co to znamená komplexní systém?

S: Na tuto otázku ti bohužel nedám žádnou jednoduchou jednověttnou odpověď. Stručně a poloodborně řečeno, komplexní systém se skládá z velkého počtu částí, které mají mezi sebou velké množství vztahů a vzájemně se ovlivňují složitým způsobem.

M: To je mi pěkně mlhavá definice. Co je to část, velké množství a složitý způsob?

S: Než zabředávat do definic, raději ti uvedu příklady – mraveniště, počasí, firma, ekosystém nebo organismus. To vše jsou komplexní systémy, protože mají hodně částí, které jsou spolu složitě propojeny. Kdežto třeba páka je jednoduchý systém – má jen pár částí a jejich vztahy není těžké popsat.

M: Ale když se na páku podívám dostatečně detailně, zjistím, že se skládá z dílčích částí a možná i u ní bych nakonec našel složité vztahy.

S: U páky by se ti složité vztahy hledaly těžko – samozřejmě bys mohl jít až na úroveň atomů, ale tam už je těch částí tolik, že můžeme počítat s průměrným chováním a uvažovat o systému pomocí statistiky. Nicméně máš částečně pravdu. Co je to systém, část či složitý vztah, závisí mimo jiné i na úhlu pohledu, na míře detailu a na časovém horizontu, s jakým svět kolem sebe zrovna studujeme. Vem si takový systém „člověk“: můžeme ho

studovat jako jeden samostatný komplexní systém, kde části jsou orgány, nebo jako dílčí část v komplexním systému, například ve firmě, nebo jako jednoduchou součást relativně neorganizovaného a nekomplexního systému, kterým je plynulý proud lidí na ulici.

M: To je mi tedy zvláštní pojem. Takže když chci, napasuji do něj skoro cokoliv. K čemu je takový pojem?

S: To není až tak zvláštní situace – vezmi si takový pojem „život“. Přesně definovat, co znamená život, by bylo také značně komplikované a přitom většina biologů se studiem života intenzivně zabývá a žádnou definici k tomu nepotřebuje. Mimochodem, moje oblíbená definice života je od Dawa Berryho: „Živý tvor je cokoliv, co umře, když do toho pořádně praštíte.“

M: V tom případě navrhuji definici: „Komplexní systém je cokoliv, čemu nerozumíme.“ Mně se to nezdá. Zavání to řečmi „všechno souvisí se vším“, „celek je víc než součet částí“ a „musíme se na to dívat holisticky“. To je teď populární, ale podle mě dost o ničem.

S: Máš pravdu, že pojem komplexní systém se často zneužívá. Nicméně studium komplexních systémů má perspektivu přinášet konkrétní výsledky. Existují univerzální metody a nástroje pro analýzu komplexních systémů, tyto nástroje navíc facilitují interdisciplinární pohled, který je pro studium komplexních systémů nezbytný. . .


M: Brzdi, používáš příliš mnoho cizích slov – to znamená, že tomu asi moc nerozumíš. Víš co, raději si to sám pořádně rozmysli, já jdu zatím hledat podklady o králících. Třeba najdu něco o komplexně systémových králících.

2.1 Jednoduché a složité

V rozhovoru zazněla definice: „Komplexní systém se skládá z velkého počtu částí, které mají mezi sebou velké množství vztahů a vzájemně se ovlivňují složitým způsobem.“ Pojdme se na tuto definici podívat podrobněji. Upřesnění potřebuje především pojem „složitý“. Co to znamená, že je něco složité?

Pojem „složitý“ má mnoho různých významů, zde jej budeme používat ve smyslu, v jakém se používá v oblasti komplexních systémů, viz například Weinberg (1975), Gell-Mann (2002). Tento význam ilustrujeme pomocí příkladu – komunikačního cvičení pro dva hráče. První hráč vidí obrázek, druhý hráč obrázek nevidí, ale zato má papír a tužku. První hráč musí obrázek popsat tak, aby druhý hráč nakreslil obrázek co nejpodobnější originálu. Důležité je, že cílem není, aby výsledný obrázek byl naprosto identický s původním, ale aby na první pohled působil stejným dojmem jako originál.

Příklady zadání pro toto cvičení jsou na obr. 2.1. Všechny tři obrázky jsou tvořeny pouze z kružnic, celkový počet kružnic je řádově stejný. Který obrázek je nejsložitější na překreslení? Obrázek nalevo je „jednoduchý“ – má pravidelnou strukturu a můžeme jej díky tomu snadno popsat: „Nakresli 49 stejně velkých kružnic uspořádaných do pravidelné mřížky.“ Obrázek uprostřed je „neorganizovaný“ – nemá žádnou struk-



Obr. 2.1: Ilustrace tří typů systémů: jednoduchý, neorganizovaný a komplexní (složitý).

Tabulka 2.1: Porovnání různých typů systémů.

Systém	Počet komponent	Interakce	Metody řešení problémů
jednoduchý	malý	pravidelné	dedukce
neorganizovaný	velmi velký	nahodilé	statistika
komplexní	velký	organizované	simulace, indukce

tu, takže by sice bylo náročné reprodukovat jej přesně, ale protože cílem je vytvořit obrázek, který působí podobně, můžeme obrázek popsat pomocí souhrnných informací: „Obrázek tvoří kružnice pěti různých velikostí, od každé velikosti nakresli asi 10 kružnic náhodně rozestých po ploše.“ Obrázek napravo je „složitý“ – rozhodně obsahuje pravidelnosti („hadi z koleček“), ale tyto pravidelnosti nejsou zcela jednoduše popsatelné.

Cvičení ukazuje, že můžeme pojem složitosti definovat jako „rozsah popisu pravidelností“. Jednoduché systémy jsou velmi pravidelné a popsat pravidelnosti není těžké. Neorganizované systémy je sice těžké popsat přesně, ale mají velmi málo pravidelností, takže popsat všechny pravidelnosti také není těžké. Komplexní systémy mají pravidelnosti, ale tyto pravidelnosti nejsou snadno popsatelné.

V tabulce 2.1 uvádíme základní charakteristiky jednoduchých, neorganizovaných a komplexních systémů. Nyní se na ně pojďme podívat trochu podrobněji.

Jednoduché systémy

Jednoduché systémy obsahují obvykle jen málo částí. V případě, že obsahují hodně částí, jsou tyto části pravidelně uspořádané nebo vzájemně nezávislé. Dílčí části sice mohou být mírně komplikované (například skládat se opět z dalších dílčích částí), ale interakce mezi částmi jsou jednoduché a snadno popsatelné. Charakteristickým rysem je tedy pravidelnost, a to jak v uspořádání, tak v chování. Příklady jednoduchých systémů jsou stroje (např. páka, kladkostroj, koloběžka), v ekonomii trh v případě monopolu, ve fyzice pohyb planety kolem hvězdy.

Jednoduché systémy můžeme analyzovat pomocí dedukce. Vyjdeme z předpokladů a pomocí exaktních logických úvah a řešení malého počtu rovnic dojdeme k jasným závěrům.

Neorganizované systémy

Neorganizované systémy mají velmi velký počet neuspořádaných částí, přičemž interakce mezi částmi jsou jednoduché, nepravidelné a mají náhodný charakter. Díky tomu můžeme chování částí aproximovat „průměrným“ chováním. Typickým příkladem neorganizovaných systémů jsou plyny, které se skládají z ohromného množství molekul, u nichž dochází k jednoduchým a nahodilým srážkám a které můžeme analyzovat například pomocí průměrné rychlosti. V ekonomii můžeme podobně analyzovat idealizovaný trh s dokonalou konkurencí (v takovém případě se typicky předpokládá, že může obchodovat kdokoli s kýmkoliv se stejnou pravděpodobností, tj. interakce jsou opět náhodné, neuspořádané).

Neorganizované systémy můžeme analyzovat pomocí statistických metod. Protože části i interakce jsou jednoduché, můžeme chování částí i vztahy mezi částmi nahradit průměrem. Pracujeme tedy se sumárními proměnnými, které vyjadřují vlastnosti velkého počtu „zprůměrovaných“ částí, např. celková teplota plynu nebo nabídková a poptávková křivka. Díky tomu opět dostáváme malý počet rovnic, které můžeme řešit. Řešení sice není úplně přesné, nicméně můžeme většinou vypočítat očekávanou odchylku, a závěry jsou tak opět docela jasné.

Komplexní systémy

Komplexní systémy mají velký počet částí, jejichž interakce nejsou ani úplně jednoduché, ani úplně náhodné, takže se nelze omezit na malý počet částí ani části nemůžeme nahradit průměrem. Příklady jsou uvedeny v tabulce 2.2.

Jak analyzovat komplexní systémy? Částí je příliš mnoho, abychom používali dedukci, protože bychom dostali velmi mnoho rovnic a neuměli bychom je vyřešit. Současně však části a interakce nejsou dostatečně jednoduché, abychom mohli jejich chování nahradit průměrným chováním. Zde přichází na řadu modelování a simulace. Na rozdíl od předchozích metod pomocí modelování a simulace většinou nedocházíme k jasným závěrům – ostatně u komplexních systémů málokdy jasné závěry existují. Modelování a simulace nám však pomáhají komplexní systémy lépe pochopit, uvažovat o nich a ovlivňovat je.

2.2 Charakteristiky komplexních systémů

Potká-li sob soba, mají radost oba. Když se potkaj tři sobi, tak se radost násobí. (Říkanka ilustrující nelinearitu komplexních systémů)

Komplexní systémy přiblížíme pomocí typických charakteristik, což je ostatně běžný přístup, viz například Sterman (2000). Jde jen o základní vodítka – ne všechny

Tabulka 2.2: Příklady komplexních systémů.

Systém	Části	Vztahy	Komplexní chování
imunitní systém	buňky	mezibuněčné signály	obrana proti infekci
mraveniště	mravenci	feromony, kontakt	koordinované chování
organizace	lidé	komunikace	produktivní činnost
trh	firmy	nákup, prodej	spekulace, krachy
ekosystém	druhy	predace, konkurence	evoluce
doprava ve městě	auta	omezování se	zácpy

komplexní systémy musí nutně vykazovat všechny charakteristiky. Nicméně už přítomnost jedné z nich činí analýzu chování systému komplikovanou.

Složité vazby a nelinearita

Důležitých vztahů mezi částmi je v komplexních systémech daleko více než u jednoduchých nebo neorganizovaných systémů. Zjednodušujícím sloganem můžeme říct, že u komplexních systémů „všechno souvisí se vším“. Například neurony v (komplexním) mozku mají každý řádově tisíce spojení, kdežto jednotlivé logické obvody v počítači mají pouze jednotky nebo desítky vstupů a výstupů.

Vztahy mezi částmi jsou navíc obousměrné, systémy jsou ovládané zpětnou vazbou. Neexistuje jednoduché rozdělení na příčiny a následky, změny ovlivňují samy sebe (více o zpětné vazbě později, zpětná vazba bude jedním z našich ústředních témat). Příklady systémů ovládaných zpětnou vazbou jsou vývoj druhů koevolucí nebo „řízení“ mraveniště, kdežto jasné rozdělení na příčiny a následky funguje například u strojů nebo hierarchického řízení organizace.

U lineárních systémů je dopad zásahu do systému přímo úměrný jeho rozsahu. Komplexní systémy jsou však většinou nelineární a vykazují potenciálně chaotické chování. Dopad zásahů do systému není úměrný velikosti zásahů. Malé zásahy mohou mít výrazný dopad, který však může být vzdálený (prostorově či časově). Například planeta pohybující se kolem Slunce je jednoduchý systém, jehož chování umíme předpovídat na mnoho let dopředu. Samozřejmě v předpovědi na sto let dopředu bude jistá odchylka, nicméně tato odchylka je lineárně úměrná nepřesnosti v našem současném měření. Naproti tomu počasí na Zemi je typický komplexní systém, a tudíž jej neumíme pořádně předpovídat ani na týden dopředu. A není to jen tím, že nedokážeme dostatečně přesně změřit aktuální stav. Počasí je nelineární systém, a tudíž i když bude měření sebestřednější, nepřesnost předpovědi bude vždy rychle narůstat.

Samo-organizace a emergentní chování

Častým důsledkem zpětných vazeb je samo-organizace. Díky zpětným vazbám může vznikat řád vycházející z malých, náhodných impulzů. Jde o řád vznikající „zespodu“, bez centrálního vedení. Chování celku není přímo zakódováno v pravidlech, kterými se řídí jednotlivci, ani neexistuje žádný vnější zdroj řádu. Například u firmy nebo

Tabulka 2.3: Změny v komplexních systémech.

Systém	Změny	Rychlost změn
nervový systém	spojení mezi neurony	sekundy až hodiny
imunitní systém	reakce buněk	hodiny až dny
firma	lidé, nástroje	měsíce až roky
živočišný druh	vlastnosti	dny až století
ekosystém	druhovému složení	roky až milénia

oblečení není těžké vysvětlit, proč vykazují určitý řád – je to tím, že existuje šéf firmy a návrhář oblečení, kteří jsou zdroji onoho řádu. Naproti tomu řád v mraveništi nebo vznik vzorů v přírodě (např. u mušlí) jsou hůře vysvětlitelné. Zde není žádný šéf mraveniště ani návrhář mušlí. Řád v těchto případech vzniká samo-organizací.

S pojmem samo-organizace úzce souvisí takzvané emergentní chování. Jde o chování, ke kterému dochází na úrovni systému, ale nemá žádný přímý ekvivalent na úrovni částí. Jak poznat, zda dochází k emergentnímu chování? Můžeme použít myšlenkový test. Co se stane, pokud odebereme malou část systému? Dokážeme z vlastností odebrané části usoudit na vlastnosti systému? Zachová si systém své vlastnosti i po odebrání části? Když z mraveniště, trhu nebo imunitního systému odebereme pár mravenců, firem nebo buněk a budeme je studovat samostatně, nedozvíme se mnoho o fungování celku. Naproti tomu když z kapaliny odebereme malý vzorek, dokážeme docela přesně určit mnohé vlastnosti celku (např. teplotu, hustotu).

Dynamičnost a adaptabilita

Komplexní systémy jsou neustále v pohybu, nepřetržitě v nich dochází ke změnám. Pokud se komplexní systém jeví v rovnováze, jde většinou pouze o rovnováhu krátkodobou, způsobenou aktuální vyvážeností probíhajících dynamických dějů, a nikoliv absencí dějů. Pro srovnání uvažme dynamickou rovnováhu mraveniště nebo města oproti statické rovnováze páky nebo domu.

Změna se může týkat nejen uspořádání jednotlivých částí, ale také pravidel, podle kterých se řídí. Tyto změny mohou probíhat na mnoha úrovních a v mnoha časových rámcích (viz tabulka 2.3). K adaptaci může docházet na úrovni částí (agenti na trhu se učí lépe obchodovat) i na úrovni systému (pokud třeba mozek chápeme jako komplexní systém).

Schopnost adaptace je tak důležitá, že se občas používá termín komplexní adaptabilní systémy. Zde nebudeme tento termín používat a ani nebudeme striktně rozlišovat mezi adaptabilními a neadaptabilními komplexními systémy. Tento rozdíl stejně většinou závisí pouze na časovém horizontu. V krátkodobém horizontu můžeme většinou považovat systémy za neadaptabilní, kdežto v dlouhodobém horizontu jsou téměř všechny komplexní systémy adaptabilní.

Další důležitou charakteristikou komplexních systémů je heterogenita – jednotlivé části systému se často odlišují a mají svoje specifika. Heterogenita je často důsledkem

adaptace na úrovni částí systému, protože každá část systému má jiné zkušenosti, kterým se přizpůsobuje, a tím se odlišuje od ostatních. Neorganizované systémy se naproti tomu skládají z téměř identických částí (např. plyn).

2.3 Studium komplexních systémů

V čem spočívá studium komplexních systémů? Nejsou to jen obecné řeči, jako že „svět je složitý“, „celek je víc než součet částí“ a „všechno souvisí se vším“? Můžeme říct něco konkrétnějšího než jen obecné analogie a metafory?

Komplexní systémy jsou ze své podstaty složité a opravdu od jejich studia nemůžeme očekávat exaktní výsledky, na které jsme zvyklí ze studia jednoduchých a neorganizovaných systémů. To ovšem neznamená, že se musíme uchýlit k planým řečem. O tom, jak studovat komplexní systémy hlouběji než na úrovni obecných řečí, je vlastně celá tato kniha. Zde zmiňme několik hlavních souvislostí.

Historie

Mnohé z věcí, které jsme zde zmínili o komplexních systémech, se mohou zdát zřejmými. Nicméně není to tak dávno, co se i nejlepším vědcům jevil svět zcela jinak. Následující věty napsal v roce 1925 Bertrand Russel, jeden z předních myslitelů první poloviny 20. století: „Nad námi i pod námi, jak v oblasti těch největších, tak i nejmenších rozměrů, všude se nám zdá, že věda dosahuje svých hranic. [...] Zákony změn lze patrně shrnout do velmi malého počtu obecně platných principů, podle nichž je možno určovat minulost i budoucnost světa, je-li znám kterýkoli sebekratší okamžik jeho dějin. Vědy zabývající se studiem neživé přírody blíží se tak stadiu dovršení, čímž přestanou být zajímavé. [...] Teoreticky by bylo možno zaznamenat všechny údaje o poloze částic do velké knihy a tu pak uložit spolu s počítačím strojem, který by na pouhé stisknutí knoflíku poskytoval tazateli žádané údaje z libovolného, do záznamu nepojatého časového období. Těžko si představit něco méně zajímavého, něco tak vzdáleného onomu vášnivému zaujetí, jímž jsou neseny dílčí objevy. Je vám, jako kdybyste po namáhavém výstupu na vysokou horu nenašli na vrcholku nic než v mlze ponořenou restauraci, kde vyhrává rádio a pije se zázvorové pivo.“ Za těch 80 let, které uplynuly od napsání těchto vět, se postoj vědců výrazně změnil. Objevky z kvantové fyziky, nerozhodnutelnosti a teorie chaosu jasně ukázaly, že nudné vysedávání u zázvorového piva jen tak nehrozí.

Postupně začali vědci uznávat, že ani detailní pochopení jednoduchých systémů je nedovede k porozumění světa jako celku. Nicméně dokud nebyly k dispozici vhodné nástroje pro studium komplexních systémů, tak vědcům nezbývalo než soustředit se i nadále na jednoduché systémy a ty komplexní přenechat filozofům.

Rozmach studia komplexních systémů nastal s nástupem počítačů. První velká centra zaměřená na výzkum komplexních systémů vznikla až v 80. letech 20. století. V současnosti zažívá výzkum komplexních systémů velký rozmach, výzkumná centra rostou jak houby po dešti, nicméně oblast je stále v raném stadiu vývoje. Dostupné

materiály mají podobu technických výzkumných prací nebo populárně psaných knížek, ucelené učebnice se objevují jen pomalu. Mnohé univerzity nabízejí samostatné kurzy na témata týkající se komplexních systémů, ucelené studijní obory však zatím příliš k dispozici nejsou.

Aktuální informace o studiu komplexních systémů a souvisejícím výzkumu lze nalézt v „Living Roadmap for Complex System Science“ (průběžně aktualizovaný dokument dostupný na internetu) a dále na stránkách institucí zabývajících se tímto tématem (například Santa Fe Institute, New England Complex Systems Institute) nebo na specializovaných internetových rozcestnících (například Complex Systems Registry).

Nástroje

Klíčovým nástrojem pro studium komplexních systémů jsou počítače. Pomocí počítačů můžeme efektivně sbírat data o komplexních systémech ve velkém a tato data analyzovat – tímto způsobem se dostáváme k informacím, které bychom bez počítačů nikdy nezjistili.

Další klíčovou rolí počítačů je provádění náročných simulací. Pomocí počítačů můžeme pracovat s výpočetními modely a simulovat jejich chování. Tyto modely nám umožňují formalizovat a testovat naše představy o fungování komplexních systémů – místo toho, abychom vedli obecné řeči, jejichž pravdivost nelze otestovat, teď můžeme naše myšlenky vyjádřit pomocí konkrétních modelů, které lze detailně zkoumat a porovnávat s realitou.

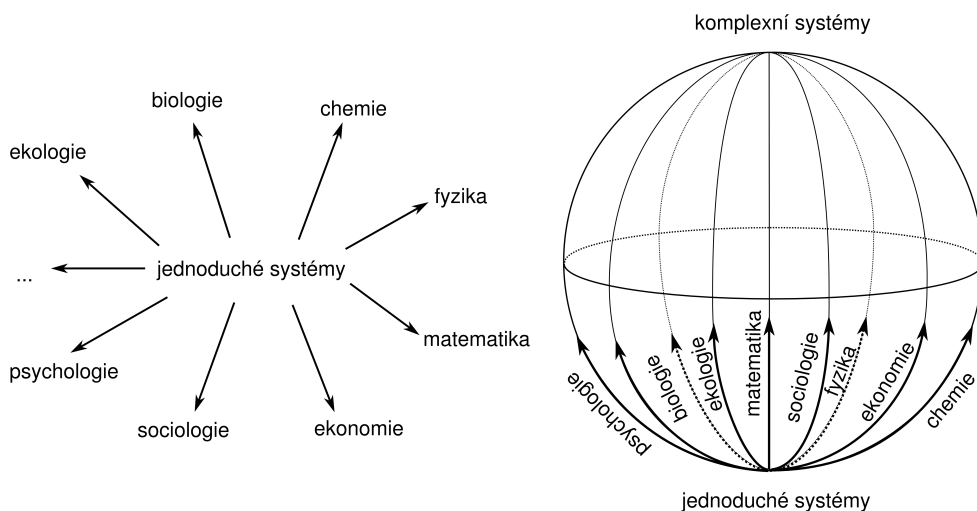
Studium komplexních systémů odlišuje od studia jednoduchých či neorganizovaných systémů nikoliv použití modelů, ale použití výpočetních modelů. Modely používáme i při dedukci či statistice – s takovými modely jsme ovšem schopni pracovat ručně. Modely komplexních systémů z principu nemohou být natolik jednoduché, abychom je byli schopni zpracovat ručně. Proto potřebujeme (výkonné) počítače.

Samotné použití počítačových metod ovšem zdaleka nezaručuje, že výsledky našeho zkoumání jsou smysluplnější než obecné řeči. Pomocí počítačů lze snadno vyrobit sofistikovaně vypadající grafy a efektní vizualizace, které nevyovídají o ničem zajímavém. Nestačí mít dobrý nástroj, je potřeba také vědět, na co se hodí a jak se používá.

Interdisciplinarita

Jedním z charakteristických rysů studia komplexních systémů je prolínání různých vědních oborů. Proč?

1. Komplexní systémy často sestávají z podsystémů z různých oblastí, pro jejich studium tedy potřebujeme znalosti a techniky z různých oborů.
2. Studium komplexních systémů se zaměřuje na obecné principy platné pro mnoho druhů komplexních systémů.



Obr. 2.2: Dva alternativní pohledy na vztah jednotlivých oborů (podle Bar-Yam, 2003).

Obr. 2.2 schematicky znázorňuje dva pohledy na vztah vědeckých oborů: pohled tradiční a pohled komplexních systémů. V tradičním pohledu vycházejí všechny obory ze stejných základů (logické myšlení a uvažování o jednoduchých systémech) a pak se rozcházejí, jak přidávají detaily specifické pro svoje obory. Studium komplexních systémů je založeno na přesvědčení, že systémy z různých oborů mají společné univerzální vlastnosti, a že tedy může být výhodný i pohled „shora“, snaha o hledání obecných principů a nástrojů a jejich aplikace ve specifických oblastech. Cílem není prosté zbourání hranic mezi obory a naivní návrat k starořecké „filozofii“ zahrnující vše. Specializace je nezbytná a potřebná, jde o to uznat, že existují společné prvky mezi vědeckými disciplínami, a musíme být schopni o těchto prvcích komunikovat.

Obecným nástrojem, který jde napříč disciplínami, je právě modelování a simulace. Modelovací techniky, které probereme v této knize, jsou dostatečně obecné na to, aby je bylo možné použít v různých oborech – to si ostatně ukážeme v třetí části knihy na konkrétních případových studiích. Jakmile si člověk tyto techniky osvojí, může je vcelku přímočaře použít pro oblast svého zájmu.

2.4 Shrnutí

- Zjednodušeně můžeme systémy rozdělit na jednoduché, neorganizované a komplexní. Komplexní systémy se vyznačují velkým počtem částí, které spolu složitým způsobem interagují.
- Charakteristické prvky komplexních systémů jsou: dynamičnost, nelinearita, velký význam interakcí a zpětných vazeb, samo-organizace, emergentní chování, heterogenita a adaptabilita.

- Studium komplexních systémů se ve větší míře rozvíjí teprve od 80. let 20. století, protože je do velké míry závislé na výkonných počítačích.
- Studium komplexních systémů je velmi interdisciplinární. Cílem je mimo jiné hledání společných prvků mezi obory a usnadnění komunikace mezi experty z různých oblastí pomocí sdílených univerzálních nástrojů.

3 Uvažování o systémech

M: Dejme tomu, že si již umím představit, co je to komplexní systém. Dokážeš mi ale vysvětlit, co mi studium této oblasti může přinést?

S: Může ti dát odpovědi na konkrétní otázky, ale to ti vysvětlím jindy. Za nejdůležitější považuji, že ovlivní tvoje uvažování o systémech. Komplexní systémy jsou, jak už název napovídá, složité. Proto je důležité o nich správně přemýšlet.

M: Tak počkat, už žiji pár let v tomhle komplexním světě a dokonce u toho i často přemýšlím. Celé generace vystačily se selským rozumem, tak co chceš vymýšlet složitějšího?

S: Ale taky s tím selským rozumem lidi nadělají spoustu chyb. Typické chyby jsou třeba lineární uvažování, krátkodobý výhled, nedomyšlení všech souvislostí. . .

M: Počkej, teď mě napadá jeden příklad, který jsem si našel do seminárky o králících. Do Austrálie si osadníci dovezli pár králíků s cílem, že je tam budou chovat a budou se mít dobře. Jenže králíci se dostali do divočiny, a protože neměli vůbec žádné přirozené nepřátele, tak se děsně přemnožili a způsobili daleko víc škody než užitku.

S: No vidíš, dobrý příklad. Dřívější generace se navíc pohybovaly ve světě, který byl značně jednodušší než dnes. V dnešní propojené, technikou ovládané době jde spousta věcí rychle a snadno – mimo jiné i děláním chyb s rozsáhlými následky.

M: S tím souhlasím. Ale znamená to něco jiného, než že je potřeba lidem připomínat, aby vždycky, než něco provedou, použili mozek?

S: Náš mozek není přirozeně uzpůsobený na uvažování o komplexních systémech. Takovému uvažování se musíme učit, k čemuž se hodí mimo jiné i modely a simulace, které nám poskytují názorné ilustrace. Potřebujeme se učit uvažovat systémově, nezaměřovat se jen na jednotlivosti. Také se musíme učit myslet decentralizovaně, potřebujeme kombinovat induktivní a deduktivní uvažování –

M: Už zase začínáš šermovat cizími pojmy. Tak ještě jednou a pomaleji.

3.1 Intuitivní myšlení

Dějiny lidstva se stávají čím dál více závodem mezi vzděláním a katastrofou. (H. G. Wells)

Hlavním cílem této kapitoly je přesvědčit čtenáře, že s pouhou intuicí nevystačíme a že se vyplatí věnovat pozornost vlastnímu myšlení, hledat v něm chyby a trénovat ho. Intuitivní myšlení (selský rozum) je rozhodně úžasná věc, protože nám umožňuje fungovat v běžném životě a dělat spoustu věcí automaticky. Kdybychom měli nad vším složitě spekulovat, nejspíš bychom se zbláznili a nic nevymysleli. Intuitivní myšlení je nicméně uzpůsobeno pro přemýšlení o jednoduchých systémech. V minulosti to většinou stačilo – člověk se zabýval jednoduchými systémy a případné komplexní systémy, které ho obklopovaly (např. počasí), stejně ovlivnit nemohl, takže moc nevadilo, když o nich přemýšlel zcestně.

Dnes se ovšem komplexním systémům nevyhneme, dokonce se ani nevyhneme tomu, abychom je ovlivňovali. Najednou nám intuitivní myšlení přestává dostačovat. Než se vrhneme na přehled alternativních stylů myšlení, pojďme se podívat na několik typických problémů intuitivního myšlení.

Lineární uvažování

I když skutečné systémy jsou často nelineární, lidé mají přirozenou tendenci extrapolovat trendy a hledat lineární závislosti. Tendence k lineárnímu uvažování byla prokázána i psychologickými výzkumy. Účastníci experimentu dostali sekvenci bodů a měli za úkol odhadnout polohu dalšího bodu v řadě. Lidé měli tendenci proložit body přímkou a podle ní odhadovat polohu následujícího bodu, a to i tehdy, když body ležely na exponenciální křivce (Sterman, 2000). Prakticky si může čtenář ověřit tuto tendenci například sledováním prognóz cen ropy nebo nemovitostí. Ačkoliv tyto ceny jsou značně nestálé a kolísavé, prognózy komentátorů v médiích často odpovídají lineární extrapolaci posledního vývoje.

Tendenci k lineárnímu myšlení pěkně ilustruje známý příklad s řasami na rybníku. Představme si velký rybník. V rybníku se objevily řasy a začaly se rychle množit. Množí se tak rychle, že se jejich počet každý den zdvojnásobí. První den je jich velmi málo, nicméně pokud nedojde k žádnému zásahu, tak během třiceti dní pokryjí celý rybník. Správce rybníku pozoruje, jak se mu postupně na rybníku množí řasy, protože jich však je na začátku málo, tak si říká, že s tím není třeba nic dělat. Pro zásah se rozhodne, až když bude polovina rybníku zamořená řasami. Kolik času mu zbude na řešení problému?

Pokud si člověk pořádně přečte zadání a chvíli se zamyslí, řešení je velmi jednoduché. Úloha sama o sobě tedy není příliš zajímavá, zajímavé je, že většina lidí, stejně jako správce vystupující v zadání, v první chvíli problém podcení a myslí si, že času zbude víc. Podvědomě totiž používáme lineární závislosti, nikoliv exponenciální. „Když 25% nárůst koncentrace CO₂ v atmosféře způsobil nárůst teploty o 0,5 °C a žádné zásadní změny klimatu, tak nárůst o dalších 25 % taky nic moc nezmění.“ To je přece jasné. Nebo ne?

Krátkodobý výhled

Ve společnosti lovců a sběračů nemělo dlouhodobé plánování příliš význam. V současné době má dlouhodobý výhled význam zásadní, nicméně naše myšlení zůstává často na úrovni lovců a sběračů. Dlouhodobý výhled nám nejde.

Krátkodobý styl myšlení ilustruje známý příběh o žábě. Pokud hodíte žabu do horké vody, rychle vyskočí a nic moc se jí nestane. Pokud ji dáte do studené a pomalu ohříváte, uvaří se, protože ve chvíli, kdy už chtěla z vody vyskočit, má svaly natolik zesláblé, že se jí vyskočit nepodaří. Z biologického pohledu tento příběh není zcela reálný (není nutné, abyste doma vařili žáby a ověřovali pravdivost, již to za vás udělali vědci). Nicméně i tak jde o užitečnou metaforu.


Pro komplexní systémy je charakteristické, že zásahy s pozitivním dlouhodobým efektem často vedou ke krátkodobému zhoršení. Ovšem vzhledem k našemu krátkodobému myšlení a krátkodobému způsobu fungování našich organizací bývá velký problém dlouhodobě výhodná řešení prosadit – konkrétně například prosazování důchodové reformy v demokratických režimech.

Zjednodušené uvažování o příčinách

Lidé mají rádi jednoduchá vysvětlení. Následky, hlavně ty špatné, si žádají jasné příčiny. Nastalo X, protože Y. Druhá světová válka vypukla, protože Hitler byl schopný demagog. Teplota stoupá, protože stoupá koncentrace CO₂. Eva opustila Martina, protože Martin příliš pije. Jednoduchá vysvětlení dělají svět pochopitelnějším. My chceme svět chápat.

V uvažování o příčinných vztazích se dopouštíme hned několika chyb. První typickou chybou je uvažování stylu „poté, tedy proto“, odborně nazývané „zaměnění konsekvence za kauzalitu“. Šaman provedl rituál a poté začalo pršet. Dobrá, šamany už jsme prokoukli, takže příliš nevěříme, že by déšť byl důsledkem šamanova rituálu. Ale co když centrální banka sníží úrokovou míru a stav ekonomiky se následnělepší, když fotbalový tým vymění trenéra a následné výsledky jsou mizerné, nebo když finanční krize v zemi A následuje po finanční krizi v zemi B? Dokážeme i v těchto situacích dobře rozlišit konsekvenci a kauzalitu a nepodlehnout zjednodušenému vysvětlení?

Další typickou chybou, které se často dopouštějí i vědci, je „zaměňování korelace a kauzality“. Pokud dvě veličiny na sobě vykazují závislost při vnesení do grafu (korelace), ještě to vůbec neznamená, že jedna z nich přímo ovlivňuje druhou (kauzalita). Typickými příklady jsou třeba počet zapalovačů v domácnosti a výskyt rakoviny plic nebo kvalita sportovního vybavení a podávaný sportovní výkon. V druhém případě drobná kauzalita jistě existuje, nicméně to není hlavní důvod dobré korelace. Záměna korelace za kauzalitu nás v těchto příkladech může vést k tomu, že v rámci boje proti rakovině plic zakážeme zapalovače a místo tréninku budeme nakupovat. Tyto příklady jsou záměrně naivní, takže chybu uvažování snadno prokoukneme. Avšak ve chvíli, kdy jsou položky trochu složitější, lidé tuto chybu dělají velmi snadno.



Obr. 3.1: Váza, nebo dvě tváře? Pohled na krychli je zespodu, nebo shora?

Jednoduché vztahy se však v komplexních systémech vyskytují málokdy. Jednoduchá vysvětlení jsou většinou špatně. Následky mají většinou více různých příčin a tyto příčiny mají různou míru vlivu. Často ani neexistuje jasné rozdělení na příčiny a následky – systém ovládá zpětná vazba. Tají ledovce, protože roste teplota planety, nebo roste teplota planety, protože tají ledovce a tím se snižuje albedo (odráživost) planety? Zpětné vazby jsou natolik důležité téma, že jim věnujeme celou další kapitolu.

Ovlivnění paradigmatem

Naše uvažování o světě je založeno na informacích, které získáváme z okolí. Už tyto „vstupní“ informace jsou ovšem často zkreslené. Máme svůj pohled na svět a je pro nás těžké vidět věci, které nejsou v souladu s tímto pohledem. Pohled na svět se často označuje jako „paradigma“ – tento termín rozšířil do obecného povědomí T. Kuhn ve své knize *Struktura vědeckých revolucí*, ve které se zabýval vlivem paradigmatu na vývoj vědy.

Paradigma má vliv nejen na vědu, ale i na naše každodenní vnímání. Máme o světě kolem nás svoje představy a očekávání. Vjemy, které z okolí získáváme, podvědomě filtrujeme, aby odpovídala těmto očekáváním. Náznornou ilustrací této tendence jsou známé optické klamy, které mohou znázorňovat dvě různé věci (obr. 3.1), ve kterých však lidé často vidí pouze jednu z nich a je pro ně náročné uvidět druhou možnost.

Podobnou tendenci ukázal výzkum s rozpoznáváním karet, ve kterém bylo měřeno, za jak krátký časový interval dokáží účastníci experimentu rozpoznat ukázanou kartu (Bruner, Postman, 1949). Kromě běžně používaných karet byly použity i nestandardní karty, např. černá srdcová. Ve svých odhadech účastníci experimentu pravidelně přizpůsobovali karty svým očekáváním (například místo černé srdcové hlásili červenou srdcovou nebo černou křížovou) a na správné rozpoznání nestandardních karet potřebovali výrazně více času než na rozpoznání standardních.

Dalším problémem, který komplikuje naše objektivní vnímání skutečnosti, je tendence hledat potvrzení toho, čemu věříme, místo potenciálních vyvrácení. Tento princip názorně ukazuje další experiment (Wason, Johnson-Laird, 1972). Představte si, že dostanete čtyři karty. Na každé kartě je z jedné strany písmeno a z druhé číslo. Vaším úkolem je zjistit, zda platí pravidlo, že karty se samohláskou na jedné straně

mají sudé číslo na druhé straně. Jsou vám ukázány karty E, K, 4 a 7. Jaký je nejmenší počet karet, které musíte otočit? Které to jsou? Experimenty ukázaly, že drtivá většina lidí zvolí karty E a 4, tj. snaží se hledat potvrzení hypotézy místo toho, aby opravdu prokázali, že hypotéza platí (k čemuž je potřeba otočit karty E a 7).

Naše paradigma, tedy to, čemu věříme, také ovlivňuje, čeho si všímáme a s jakými informacemi pracujeme. Když několik nezávislých měření začalo ukazovat na problém ozónové díry, vědci z NASA začali zkoumat, proč měření z jejich satelitu trend snižující se hladiny ozónu neukázala. Zjistili, že měřicí zařízení bylo naprogramováno tak, aby nízká měření zamítlo. Návrháři přístroje předpokládali, že tak nízký výsledek musí být způsoben chybou měření (Meadows et al., 2004).

Jak je vidět, nejen naše uvažování, ale už naše vnímání skutečnosti může být hodně zkreslující. Co s tím můžeme dělat? Zcela se zkreslení nikdy nevyhneme, ale pokud si jsme hrozícího zkreslení vědomi, můžeme se alespoň snažit mu příliš nepodlehout. Darwin prý u sebe stále nosil deníček, do kterého si zapisoval pozorování, která nebyla v souladu s jeho teoriemi. Všiml si totiž, že má tendenci pamatovat si to, co se mu hodí do teorií, a zapomínat to, co se mu nehodí.

Neintuitivnost komplexních systémů

Nemůžeme řešit problémy stejným stylem myšlení, jakým jsme je vytvořili.

(A. Einstein)

Když porovnáme seznam charakteristik komplexních systémů a častých chyb lidského myšlení, není divu, že komplexní systémy se chovají často velmi neintuitivně a naše zásahy do nich mají nežádoucí důsledky.

Příkladem neintuitivního chování jsou požáry v amerických národních parcích. Správa národních parků se jistý čas snažila požáry systematicky hasit. Přestože cílem tohoto opatření bylo chránit přírodu, výsledný efekt byl spíše opačný. Místní ekosystémy jsou přizpůsobeny pravidelným požárům a například sekvoje požáry potřebují pro vyklíčení svých semen. Díky hašení se navíc kumulovalo velké množství suchého dřeva a jednou za čas vznikl tak velký požár, že jej nebylo možné uhasit. Podobný efekt mají některá protipovodňová opatření, která narušují místní ekosystémy a vedou k méně častým, ale o to silnějším povodním.

Dalším typickým příkladem je budování silnic. Když postavíme více silnic, tak bude méně zácp. To je jasné, ne? Bohužel ne. Budování silnic má více dopadů než jen pouhé zvýšení kapacity. Silnice zvyšují atraktivitu místa a tím přilákají více lidí. Když je víc silnic, tak si víc lidí koupí auto – vidím, že se staví silnice, tak si koupím auto a dům na druhém konci města. Výdaje na silnice mohou znamenat omezení hromadné dopravy a o to větší nárůst automobilistů. Celkově tedy nové silnice znamenají nejen novou kapacitu, ale i nová auta a nové zácpy. Uvedený popis není (jenom) pesimistický strašák environmentálně laděného cyklisty, ale popis reálného vývoje například v Londýně nebo Los Angeles (Sterman, 2000).

Příklady neintuitivnosti komplexních systémů je kolem nás celá řada: informační technologie a „bezpapírová kancelář“ vedoucí ke zvýšené spotřebě papíru, zařízení

šetřící čas vedoucí k nedostatku času, bezpečná auta vedoucí k nebezpečné jízdě, zákaz potratů, který má velmi malý efekt na množství potratů a porodnost.

Situace je o to horší, že lidé nejen často uvažují chybně, ale ještě k tomu mají přílišné sebevědomí a ve své uvažování a odhady pevně věří (Sterman, 2000). Tento fenomén byl důkladně prozkoumán experimenty, ve kterých lidé odpovídali na otázky a odhadovali svoji úspěšnost – výsledky systematicky ukazují, že lidé si věří daleko víc, než je oprávněné. Podle výsledků experimentů se zdá, že jediní, kdo mají realistický odhad, jsou profesionální hazardní hráči a lidé zabývající se předpovědí počasí.

Konkrétní zajímavý příklad přílišného sebevědomí ukazuje průzkum názorů expertů na klimatické změny (Nordhaus, 1994) – experti se měli vyjádřit k pravděpodobnému dopadu klimatických změn na ekonomiku. Výsledky průzkumu ukázaly, že ekonomové odhadují dopad klimatických změn na ekonomiku daleko mírněji než klimatologové. To samo o sobě není až tak překvapivé. Co je překvapivé, je důvěra, jakou zúčastnění experti měli ve svoje odhady. Každý z nich měl určit interval 90% jistoty svého odhadu. Intervaly jistoty byly často natolik úzké, že vylučovaly názory většiny ostatních expertů.

Jakmile máme co do činění s komplexními systémy, musíme tedy být velmi ostražití a nepodlehnout nástrahám našeho příliš zjednodušujícího intuitivního myšlení. Podívejme se tedy trochu podrobněji na to, jak vlastně přemýšlíme. Styly myšlení rozdělíme podle toho, čemu věnujeme pozornost (celku nebo částem), jak provádíme úvahy (deduktivně nebo induktivně) a kde hledáme příčiny dějů (v centru nebo ve zpětných vazbách).

3.2 Systémové myšlení

My všichni jsme cestující v letadle, které musíme nejen řídit, ale přestavět celou konstrukci za letu. (J. D. Sterman)

Po kritice intuitivního myšlení se podíváme, jak můžeme svoje myšlení vylepšit. Probereme různé styly myšlení, přičemž popisy jednotlivých stylů záměrně vyhrdíme, aby lépe vynikly hlavní principy. Svět však není černobílý a myšlení také ne – je nutno pamatovat, že v praxi vždy používáme kombinaci různých typů myšlení.

Jako první probereme systémové myšlení, které se cíleně snaží o pohled na systém jako celek a na studium vztahů mezi jednotlivými částmi. Stručně vyjadřuje cíl systémového myšlení slogan: „Vidět les, nejen stromy.“

Souvislosti: Systémové myšlení popisují podrobněji například Sterman (2000) a Weinberg (1975).

Podobenství o slepých mužích

Základní myšlenku systémového myšlení vyjadřuje také podobenství o slepých mužích a slonovi (toto podobenství však nevymysleli moderní systémoví myslitelé, bývá připisováno různým východním učením). Pět slepých mužů přijde ke slonovi a snaží

se zjistit, jak vypadá. Každý z nich důkladně ohmatá jednu část slona a hned si udělá představu o tom, jak slon vypadá:

- První ohmatá bok slona a tvrdí: „Slon je jako zeď.“
- Druhý ohmatá nohu a tvrdí: „Slon je jako strom.“
- Třetí ohmatá chobot a tvrdí: „Slon je jako had.“
- Čtvrtý ohmatá ucho a tvrdí: „Slon je jako vějíř.“
- Pátý ohmatá ocas a tvrdí: „Slon je jako lano.“

Když se snažíme zkoumat svět kolem nás, jsme také v mnoha ohledech slepí a často dopadneme podobně jako popsaní muži. Ano, je těžké vědět, jak vypadá slon, když je člověk slepý. Ale to neznamená, že bychom měli rezignovat a spokojit se s tvrzením, že slon je jako lano.

Principy

Základní principy systémového myšlení jsou následující:

- pohled z nadhledu, na celkový obráz, do šířky, na celek, nikoliv do hloubky, na detaily,
- postup od obecnějšího ke specifitějšímu,
- soustředění na dynamiku procesů oproti statickému vnímání světa,
- důraz na vztahy, souvislosti, interakce,
- uvědomění si role zpětné vazby,
- uvědomění si relativnosti, uvažování vlivu pozorovatele,
- dlouhodobé uvažování.

Tyto principy sice dobře znějí, ale samy o sobě jsou to dost obecné fráze. Přinářejí riziko, že skončíme u planých řečí o složitosti světa a provázanosti všeho se vším. V systémovém myšlení proto hrají důležitou roli právě (výpočetní) modely. Sestavování modelu nám pomáhá utřídit si myšlenky, hledat vztahy, vidět zpětné vazby. Modely nás však hlavně nutí myšlenky jasně formulovat. Výpočetní model musí být přesně specifikovaný – jinak ho prostě na počítači nespustíme. To nás nutí vyjadřovat se přesně, nepoužívat mlhavé formulace, neujasněné předpoklady a plané fráze. Se systémovým myšlením souvisí především systémové modelování (kapitola 6).

Redukcionismus a holismus

Systémové myšlení souvisí s pojmy holismus a redukcionismus. Redukcionismus je založen na přesvědčení, že systému jako celku můžeme porozumět na základě detailního porozumění jednotlivým částem. Redukcionisticky problémy řešíme metodou rozděl a panuj – rozdělením problému na části a samostatným řešením dílčích částí. Holismus je oproti tomu založen na přesvědčení, že „celek je víc než součet částí“, tj. že pro porozumění systému jako celku nemůžeme studovat pouze části, ale že musíme klást důraz i na vztahy mezi nimi. Uvedený popis je zjednodušený, navíc termín

holismus bývá často používán až s mystickým podtextem, který nemá se systémovým myšlením a modelováním nic společného, takže nebudeme tyto pojmy dále příliš rozebírat.

Nicméně i nad tímto zjednodušeným popisem je dobré si uvědomit, že není jedno dobře a druhé špatně. Každý přístup se hodí na jiný typ problémů. Při návrhu domu se hodí postupovat z velké části redukcionisticky, kdežto při pozorování mraveniště je lepší dívat se holisticky. Většinou je navíc potřeba kombinovat oba přístupy. Je však smysluplné klást důraz na holistický pohled a systémové myšlení, protože v naší kultuře historicky převažuje redukcionistický přístup. Jak funguje současná věda, lékařství, vzdělání? Většinou rozsekáme systém na části (vědecké disciplíny, orgány těla, školní předměty) a pak se zabýváme každou částí samostatně. Jsou samozřejmě případy, kdy je redukcionistický přístup vhodný, mnohé problémy však takto nelze řešit. S rostoucí provázaností jednotlivých částí světa (technologie, mezinárodní politika, ekologie, náboženství, sociální problémy) roste nutnost holistického pohledu.

3.3 Induktivní a deduktivní myšlení

Jak provádíme úvahy o systémech? Máme dvě základní metody: dedukci a indukci. Dedukce je logicky korektní, ovšem málokdo ji reálně používá. Indukce nezaručuje platnost závěrů, ale přesto je často používána. Pomocí modelování a simulace můžeme tyto dva styly myšlení sblížit. Jak simulace zapadá mezi indukci a dedukci, rozebereme v kapitole 5.

Deduktivní myšlení

Deduktivní myšlení postupuje od obecného ke konkrétnímu. Z obecně platných principů vyvozujeme logickou úvahou platné závěry. Klasický příklad deduktivní úvahy:

Všichni muži jsou smrtelní.

Sokrates je muž.

Proto: Sokrates je smrtelný.

Deduktivní uvažování je korektní a snadno formálně uchopitelné. Vědecké argumenty se (většinou) snaží postupovat podle zásad deduktivního myšlení. Každodenní realitě však deduktivní myšlení neodpovídá – lidé zvládají přemýšlet deduktivně pouze o jednoduchých a jasně formulovaných problémech a i to je stojí hodně sil.

Induktivní myšlení

Induktivní myšlení postupuje od konkrétního k obecnému, od pozorování příkladů k zobecňování a usuzování o budoucím vývoji. Klasický příklad induktivní úvahy:

Doposud každé ráno vyšlo slunce.

Proto: Slunce vyjde každé ráno.

Induktivní uvažování sice není příliš korektní, nicméně lidé ho velmi často a úspěšně používají. Typickým příkladem ze života je ovládnání nového přístroje (např. mobilního telefonu). Deduktivní přístup by odpovídal tomu, že si sedneme, přečteme si kompletní návod, a když potřebujeme s přístrojem něco provést, tak na základě informací z návodu odvodíme posloupnost kroků, které máme udělat. Induktivní přístup odpovídá tomu, co dělá většina lidí: prostě začneme přístroj zkoušet používat a na základě zkušeností se nejdříve učíme posloupnosti konkrétních kroků a postupně i obecné principy fungování přístroje.

3.4 Decentralizované myšlení

Při přehledu častých chyb jsme uvedli, že lidé mají tendenci hledat jednoduchá vysvětlení. Tato vysvětlení bývají centralizovaná: hledáme jednu příčinu, jeden zdroj problémů, jednoho původce. Pro porozumění komplexním systémům je však často potřeba naučit se uvažovat decentralizovaně.

V případech decentralizovaného myšlení jsou obzvláště užitečné právě modely, které nám názorně ukazují, jak mohou systémy fungovat decentralizovaně, bez globálního vedení. Proto zde nebudeme zatím zacházet příliš do podrobností a ilustraci většiny principů decentralizovaného myšlení necháme na pozdější kapitoly, ve kterých už budeme mít k dispozici konkrétní modely.

Souvislosti: Decentralizované myšlení podrobněji rozebírá Resnick (1997). Za účelem ilustrace decentralizovaného myšlení se používá hlavně modelování pomocí buněčných automatů a pomocí agentů (kapitola 7). Konkrétní příklady jsou uvedeny v kapitole 12.

Intuitivní hledání centra

Při centralizovaném myšlení hledáme centralizované příčiny: vedení, které dává pokyny, semínka, od nichž se odvíjí růst. Když lidé jedoucí v autě narazí na zácpu na silnici, většinou automaticky předpokládají, že existuje jasně identifikovatelný důvod, proč se zácpa vytvořila – třeba nehoda, úzká silnice nebo křižovatka v opravě. Takový důvod však existovat nemusí, zácpa může vzniknout i „samo-organizovaně“ na několikaproudé dálnici bez překážek. Náhodou se nakumuluje dostatek aut blízko sebe, musí přibrzdit, ti za nimi musí přibrzdit ještě víc a tak dál.

Tendenci k centralizovanému myšlení prokázal výzkum v Izraeli, kdy se zjišťoval názor dětí na fungování tamější kapitalistické ekonomiky (Leiser, 1983). Ukázalo se, že většina dětí si myslí, že platy vyplácí a jejich výši stanovuje nikoliv zaměstnavatel, ale vláda. Část dětí dokonce přikládala na vrub vládě i organizaci stávek.

Další příklady najdeme v říši zvířat. Všimněme si například zavádějícího názvu „královna“ u mravenců, který evokuje centralizované řízení, a přitom královna má ve skutečnosti na starosti především kladení vajíček. V tomto případě je sice asi většině lidí jasné, že královna neovlivňuje mravenišť stejným způsobem jako lidská

královna království, nicméně pokud uvážíme například hejna, najdeme větší rozpory. Lidé mají tendenci předpokládat existenci dominantního ptáka, který hejno vede. Tak tomu ovšem vůbec nemusí být.

Robustnost a efektivita

Monarchie je jako nádherný koráb plující pod plnými plachtami majestátně vpřed. Najednou narazí na útes a klesne navždy ke dnu. Demokracie je jako vor. Nikdy, nikdy se nepotopí, ale proklatě, nohy máte furt ve vodě! (neznámý autor)

Jeden z důležitých rozdílů mezi centralizovanými a decentralizovanými systémy se týká robustnosti a efektivity. Obecně lze říci, že decentralizované systémy jsou více odolné k chybám, ale také méně efektivní.

Srovnajme například stroje (centralizované systémy) a přírodní systémy (decentralizované systémy). Stroje dokáží vykonávat určitý úkon velmi efektivně, ale jeden zaseknutý šroub je může naprosto rozhodit. Přírodní systémy nebývají plně efektivní, ale zato jsou robustní. Když člověk chvíli sleduje mravence pobíhající chaoticky tam a zpátky, diví se, že vůbec zvládnou potravu shromáždit. Na rozdíl od robota však mraveniště přežije ránu kyjem.

Podobně to platí pro systémy řízení státu a ekonomiky. Centralizované systémy (diktatura, plánované hospodářství) jsou potenciálně daleko efektivnější a pružnější než decentralizované systémy (demokracie, volný trh). Centralizovaná řešení jsou však velmi závislá na tom, kdo zrovna sedí v centru a co ho právě napadne, a tudíž jsou daleko méně robustní.

Podobně jako u ostatních stylů myšlení ani v případě centralizovaného a decentralizovaného myšlení nelze jednoznačně říct, že jedno je dobré a druhé špatné. Je potřeba hledat vhodné řešení pro danou situaci, volit kompromisy, vyvážit efektivitu a robustnost.

3.5 Shrnutí

- Komplexní systémy jsou neintuitivní. Se selským rozumem nevystačíme.
- Potřebujeme si osvojit různé metody myšlení o systémech. Neexistuje univerzální přístup ke světu, měli bychom vždy používat ten, který je zrovna vhodný pro danou situaci, a být schopni kombinovat různé styly myšlení.
- Popsali jsme styly myšlení rozdělené podle toho, čemu věnujeme pozornost (části – redukcionismus, celek – holismus), jak uvažujeme (dedukce, indukce) a kde hledáme příčiny dějů (centralizovaně, decentralizovaně).
- K osvojení způsobu myšlení, který běžně nepoužíváme, nám mohou pomoci modely, což ukážeme v dalších kapitolách.

4 Zpětná vazba

M: Dobře, tak jsi mě přesvědčil, že je potřeba učit se uvažovat i jinak než jen selským rozumem. Ale jak na to? Zkus mi ukázat příklad s králíky, třeba to rovnou využiju do seminárky.

S: Jak už jsem ti říkal, jedním z nedostatků intuitivních úvah o komplexních systémech je zjednodušené uvažování o následcích a příčinách. Hledáme vysvětlení typu nastalo X, protože Y. X je příčina, Y je následek.

M: A co je na tom špatně? Když sameček oplodní samičku, budou malí králíci. Příčina – následek. Všechno sedí.

S: Tak to funguje ale jen u jednoduchých systémů nebo u dílčích částí systémů. U komplexních systémů jednoduché rozdělení na příčiny a následky neexistuje. Představ si populaci divokých králíků. Když ji budeš pozorovat v čase, zjistíš, že velikost populace osciluje, často dokonce docela pravidelně. Dokážeme najít jednu jasnou příčinu těchto oscilací? Ne, oscilace jsou důsledkem mnoha vzájemně propletených vazeb.

M: Ale to jsi zase skončil u toho, jak všechno souvisí se vším a jak je to propletené.

S: Od toho máme právě modely, které nás nutí abstraktní mlhavé myšlenky jasně vyjadřovat. Mohl bych zkusit udělat model s králíky, na kterém bych ti to předvedl. Ale ještě před modelováním ti ukážu analýzu zpětnovazebních cyklů. Naučit se uvažovat o zpětnovazebních cyklech je totiž základ. Takže tady si zakreslíme počet králíků, tady máme pozitivní zpětnou vazbu, a tady. . .

M: Zpomal. Pozitivní zpětná vazba je co?

S: Zjednodušeně řečeno: změna, která způsobuje svůj vlastní nárůst. V našem případě, čím víc je králíků, tím víc králíků se rodí, a tím víc je králíků. . .

M: . . . a tím víc králíků se rodí. Chápu. A dál?

S: A pak tady máme negativní zpětnou vazbu. Což je zjednodušeně řečeno změna, která v konečném důsledku způsobuje svoje vlastní zmenšení. Čím víc je králíků, tím méně je dostupné potravy, takže je větší konkurence mezi králíky, část králíků zemře hladu, a tedy králíků ubude.

M: Takže ty dvě zpětné vazby jsou propojené?

S: Správně. Právě tomu se říká zpětnovazební diagram. V reálném případě bude těch propojených vazeb ještě daleko víc. Pro chování systému je zásadní, která zpětná vazba systému dominuje. Pokud dominuje negativní zpětná vazba, systém se udržuje v rovnováze.

M: Můžu si tuto variantu představit jako populaci králíků u babičky, kde velikost populace je udržována na stabilním stavu odpovídajícím velikosti králíkárně a kde negativní zpětnou vazbu zprostředkovává dědeček?

S: Správně. A pokud dominuje pozitivní zpětná vazba, systém se vyvádí pryč z rovnováhy.

M: Jako když vysadili králíky v Austrálii?

S: Přesně tak. Samozřejmě žádná pozitivní zpětná vazba nemůže zvětšovat změnu do nekonečna a časem narazí na regulující negativní zpětnou vazbu – i ta Austrálie uživil jen omezený počet králíků. Ale myslím, že hlavní princip už chápeš. Možná ti ale radši dám ještě několik dalších příkladů. . .

4.1 Základní zpětné vazby

My tvarujeme svoje budovy; poté ony tvarují nás. (W. Churchill)


Zpětná vazba tvoří jednu z ústředních linek celého textu, a proto jí věnujeme celou samostatnou kapitolu, ve které popíšeme obecné principy. Tyto principy ilustrujeme také na několika příkladech, řadu dalších příkladů zpětných vazeb zmíníme v následujících kapitolách.

Co je to zpětná vazba? Tento pojem je těžké jednoznačně popsat, protože se v různých variantách vyskytuje v mnoha rozličných oblastech. Slovníková definice praví, že jde o „proces, při kterém je část výstupu systému současně vstupem pro další činnost tohoto systému“. Obr. 4.1 ilustruje základní princip a uvádí konkrétní příklady. Jiný možný pohled je dívat se na zpětnou vazbu jako na cyklus příčin a následků bez jasných vstupů a výstupů. Příčiny v jedné části systému způsobují následky, které, na oplátku, způsobují změny v původních příčinách.

Zpětnovazební cykly dělíme na pozitivní a negativní – základní rozdíl mezi nimi je ilustrován na obr. 4.2. Zdůrazněme, že jde o čistě technické dělení, a nikoliv o emotivní hodnocení. Nejdříve rozebereme tyto dva základní typy zpětné vazby samostatně a ilustrujeme je na příkladech, které jsou záměrně zjednodušeny, aby na nich vynikl popisovaný typ vazby. V reálných systémech se pozitivní a negativní vazby vždy doplňují a vyvažují – tím se zabýváme v závěru kapitoly.

Negativní zpětná vazba

Negativní zpětná vazba znamená, že změna v jedné složce zpětnovazebního cyklu vede v konečném důsledku ke zmenšení této změny. Negativní zpětná vazba má regulační charakter, protože udržuje systém v rovnováze. Pokud jsou v systému přítomna zpoždění, může docházet k oscilacím okolo rovnovážné polohy.



Obr. 4.1: Zpětná vazba v různých oborech.

Typický příklad negativní zpětné vazby je termostat řídící teplotu v místnosti. Termostat průběžně měří aktuální teplotu v místnosti a porovnává ji s požadovanou hodnotou. Když je příliš chladno, zapne topení, je-li příliš teplo, topení vypne (případně zapne klimatizaci). Teplota se tak, s mírnými oscilacemi způsobenými zpožděním, udržuje kolem zadané hodnoty.

Podobně funguje jakékoliv cílené řízení. Například naše schopnost řídit jízdní kolo či balancovat na kládě je založena na negativní zpětné vazbě – jakmile dojde k výchylce z rovnováhy, uděláme korekci, která tuto výchylku zmenší. Alkohol v krvi způsobuje zpoždění ve zpětnovazebním cyklu, což vede k výraznějším oscilacím (a případně i opuštění rovnovážného stavu).

Negativní zpětná vazba však rozhodně nemusí být řízená. Mnoho „neřízených“ negativních zpětných vazeb najdeme v ekonomii. Čím víc je v určité profesi volných pracovních míst, tím je větší zájem o studium této profese a tím pádem časem klesá počet volných pracovních míst. Když obchodník zvýší cenu, klesne mu poptávka, což jej přinutí cenu snížit (kvůli konkurenci). Negativní zpětná vazba tedy hraje roli pověstné neviditelné ruky trhu.


Další příklady uvedeme jen heslovitě: velikost populace – dostupná potrava, množství CO₂ ve vzduchu – růst rostlin, množství vědomostí – rychlost zapomínání.

Pozitivní zpětná vazba

Tomu, kdo má, totiž bude dáno, a tomu, kdo nemá, bude vzato i to, co má. (Mk 4:25)

Pozitivní zpětná vazba znamená, že změna v jedné složce zpětnovazebního cyklu vede v konečném důsledku k zvětšení této změny. Pozitivní zpětná vazba má deregulační charakter a vyvádí systém pryč z rovnováhy, čímž může mít destruktivní charakter, nebo také může vést ke vzniku nových struktur. Pozitivní zpětná vazba stále zvětšuje svůj efekt, nicméně protože nic nemůže růst do nekonečna, tak vždy narazí na určitý limit, který je většinou zprostředkován vyvažující negativní zpětnou vazbou. Přítomnost pozitivní zpětné vazby je často skrytá za případy, kdy se snažíme chybně hledat jednoduchá centralizovaná vysvětlení.

Příklady destruktivních pozitivních vazeb jsou epidemie, nádory, výbuchy. Když přibude nemocných jedinců, víc zdravých jedinců přijde do kontaktu s nemocnými, přibudou nově nakažení, a počet nemocných se tedy ještě zvýší. Podobně funguje šíření zhoubného nádoru nebo jaderná exploze.



Obr. 4.2: Ilustrace dvou typů zpětných vazeb, šedý míček je v rovnováze, černý míček je ve vychýlené pozici.

Příkladem pozitivní zpětné vazby, která vede ke vzniku nových struktur, je formace měst. Na křižovatce cest se usídlí několik rodin, začne probíhat obchod, místo se stává atraktivním pro nové usedlíky. Čím víc lidí na onom místě bydlí, tím víc možností místo poskytuje, tím je atraktivnější a tím víc lidí se na něm usidluje.

Konstruktivní přínos má pozitivní zpětná vazba také při získávání vědomostí. Čím víc člověk ví, tím snáze si uvědomuje souvislosti, lépe mu nové vědomosti zapadnou do mozaiky dosavadních znalostí, snadněji se tedy učí nové věci, a o to víc ví.

Typickým příkladem pozitivní zpětné vazby je známý princip „bohatší se stávají bohatšími, chudší chudšími“. Peníze rodí peníze a dluhy rodí dluhy. Tato pozitivní zpětná vazba probíhá přímo prostřednictvím úroků a dále nepřímo pomocí dalších zpětných vazeb: bohatství – vzdělání – pracovní příležitosti, chudoba – nevzdělanost – kriminalita.

Pozitivní zpětná vazba je také základem popularity, ať už jde o vědu (povědomí o vědecké práci – množství citací), sport (úspěšnost fotbalového klubu – peníze od sponzorů) nebo o kulturu (popularita celebrit – zájem médií). Díky těmto pozitivním zpětným vazbám se tak může stát, že ze dvou vědců, kteří přijdou na stejný objev, se proslaví jen jeden, nebo že existují celebrity známé jen tím, že jsou známé.

Pozitivní zpětná vazba může také ovlivňovat vztahy mezi lidmi. Někdo mě trochu naštvete, tak se zatvářím uraženě, on se zalekne, tak se mnou nemluví, já na něj tedy taky nemluví a tak dále. Na začátku může jít o detail či o nedorozumění a díky pozitivní zpětné vazbě je z toho vyhrocený spor. Podobný princip se bohužel může projevit také na úrovni celých národů a může vyústit v genocidu a vleklou občanskou válku.

Na závěr uvedme dva příklady z přírody: albedo a erozi. Albedo (odrazivost, bělost) planety udává, jaký podíl slunečního záření se odrazí zpět do vesmíru. Albedo planety je spojeno pozitivní zpětnou vazbou s plochou ledovců. Čím větší albedo, tím větší zima, tím více ledovců, tím větší albedo. Nebo také naopak: čím větší teplo, tím méně ledovců, tím menší albedo, tím větší teplo. Tento mechanismus je jedním z faktorů ovlivňujících střídání dob ledových a meziledových a jedním z důvodů, proč není dobré brát klimatické změny na lehkou váhu. Také eroze je typický příklad pozitivní zpětné vazby: čím větší je eroze povrchu, tím menší je pokrytí rostlinami a tím rychleji eroze postupuje.

4.2 Kombinace zpětných vazeb

Výše uvedené příklady jsou značně zjednodušující, především pozitivní zpětná vazba se nikdy nevyskytuje sama o sobě a je vždy vyvážena negativní zpětnou vazbou. V reálném systému navíc nemáme jen dvě položky, které se navzájem ovlivňují. Vzájemně propletených příčin a následků je vždy více a dohromady vytváří komplikované zpětnovazební cykly.

Souvislosti: Zpětných vazeb v určité formě se týká většina literatury uvedené na konci textu. Strukturu zpětnovazebních cyklů podrobněji rozebírá například Sterman (2000).

Struktura zpětnovazebních cyklů

Pro základní porozumění systému vytváříme diagram znázorňující strukturu zpětnovazebních cyklů:

1. Zapišeme si klíčové položky systému.
2. Pokud mezi dvěma položkami existuje vztah příčina – následek, pak mezi nimi zakreslíme šipku. Šipku označíme znaménkem plus (resp. mínus), pokud jde o pozitivní vztah, tj. nárůst příčiny způsobuje nárůst (resp. pokles) následku.
3. Každý cyklus označíme jako pozitivní (resp. negativní) zpětnou vazbu, pokud obsahuje sudý (resp. lichý) počet negativních vztahů.

Příklad analýzy je uveden na obr. 4.3 – jde o příklad s budováním silnic, který jsme popsali v minulé kapitole.

Analýza struktury zpětnovazebních cyklů nám pomáhá zorientovat se v systému a najít nejdůležitější složky a zpětné vazby ovlivňující chování systému. Sama o sobě nám tato analýza nedává žádné specifické odpovědi, je však velmi užitečným prvním krokem při modelování.

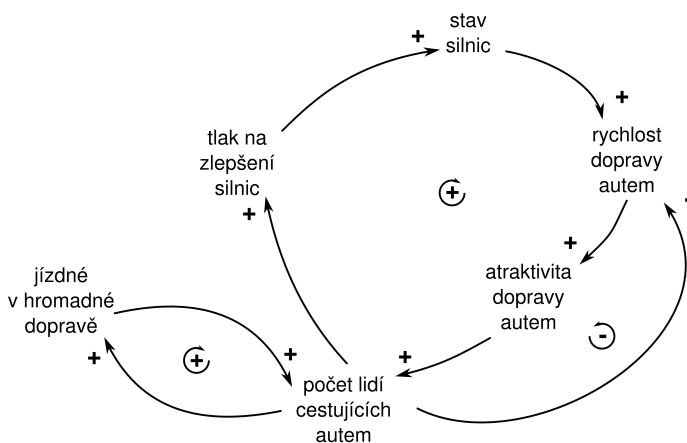
Rovnováha

Systém v rovnováze může na první pohled vypadat, jako že v něm neprobíhají žádné důležité procesy. Pravda je však často jiná: rovnováha bývá důsledkem vyváženosti protikladných sil (zpětných vazeb). I drobný zásah do systému, který naruší některou z těchto sil (zpětných vazeb), může znamenat opuštění rovnováhy.


Způsobů, jakými může být systém v rovnováze, je hodně a vzájemně se výrazně liší. Rovnováha může být vysoce stabilní i vysoce nestabilní. Lidé však mají tendenci zaujímat určitý postoj a ten aplikovat univerzálně. Zjednodušeně můžeme rozlišit čtyři pohledy na povahu rovnováhy ve světě (viz též obr. 4.4):

Dobrotivý svět Svět je předpověditelný, robustní, stabilní, v systémech dominují negativní zpětné vazby.

Pomíjivý svět Svět je křehký, nestabilní, změny nevratné, v systémech dominují pozitivní zpětné vazby.



Obr. 4.3: Příklad analýzy zpětnovazebních cyklů.



Obr. 4.4: Čtyři pohledy na povahu světa podle Adamse (1995).

Tolerantní svět Svět je kombinací předchozích dvou situací. Do určitých limitů stabilní a předpověditelný, po překročení těchto limitů následují překvapení.

Vrťavý svět Svět je nepředpověditelný a chová se náhodně.

Opět to není tak, že by jeden z těchto pohledů byl správný a ostatní špatné. Je potřeba neustrnout na jednom z nich a pro jednotlivé případy znovu zvažovat, jak zkoumané systémy fungují.

4.3 Shrnutí

- Zpětné vazby řídí chování komplexních systémů. Dobré pochopení fungování zpětných vazeb je pro porozumění komplexním systémům zásadní.
- Negativní zpětná vazba koriguje velikost změn a udržuje systém v rovnováze. V přítomnosti zpoždění vede k oscilacím.
- Pozitivní zpětná vazba zvětšuje velikost změn, čímž systém vyvádí z rovnováhy. Může však přitom vytvářet nové struktury.
- V reálných systémech se pozitivní a negativní zpětné vazby vzájemně kombinují a doplňují. Pro porozumění systému používáme zpětnovazební diagramy.
- Je více způsobů, jakými může být systém v rovnováze. Stabilita rovnováhy záleží na tom, které zpětné vazby systému dominují.

5 Modelování a simulace

S: Tak jsem ti na ukázkou udělal model s králíky. Sleduj.

M: No pěkné, barevné tečky blikají chaoticky na monitoru. Co to má znamenat?

S: Dívej, tady ty hnědé pohybuující se tečky jsou králíci. Zelené čtverečky představují trávu. Když je králík hodně nažraný, tak se množí, když málo, umírá. Takže tu máme pěkně pozitivní zpětnou vazbu: čím víc králíků, tím víc mladých a tím víc králíků. A také tu máme korigující negativní zpětnou vazbu: čím víc králíků, tím méně jídla, tím méně králíků. Model ukazuje, jak dopadá interakce těchto dvou zpětných vazeb. Tady na tom grafu jsou počty králíků v průběhu času. Vidíš, jak to pěkně osciluje? To je typické pro systém dominovaný negativní zpětnou vazbou se zpožděním. . .

M: Tak počkat. Možná bys neměl pořád sedět za počítačem a měl by ses jít občas podívat ven. Viděl jsi někdy králíka? Většinou nevypadá jako hnědé kolečko. A asi jsi moc nedával pozor v biologii – králíci se nemnoží buněčným půlením, když jsou dost nažraní. Dochází tam k jisté fyzické interakci, víš?

S: Nebuď drzý. To samozřejmě vím. Ale základ dobrého modelu je volba vhodné abstrakce. V tomto modelu mě zajímá populační dynamika a ta nezáleží na tvaru králíka ani na detailech průběhu jistých interakcí.

M: No ale stejně, k čemu ti to je? Nebylo by lepší jít do přírody a tam pozorovat živé králíky?

S: Účel tohoto modelu je především pedagogický – chtěl jsem ti na něm ukázat ty zpětné vazby, což je daleko snazší na modelu než v realitě. Realita je příliš složitá a těžko se přímo na ní něco vysvětluje. A kromě toho, i to, co ty vnímáš jako realitu, je stejně jen jakýsi tvůj mentální model, a ne opravdová realita. Otázka není, jestli používat modely, ale jaké modely používat.

M: To mě nenapadlo, takto o tom uvažovat. Já jsem si myslel, že modely jsou spíš na předpovídání budoucnosti.

S: Existuje spousta různých typů modelů a mohou mít mnoho různých účelů. O předpovídání budoucnosti může jít taky – k tomu jsou třeba modely počasí. Může jít však také o návrh systémů, zkoumání hypotéz, trénink, zábavu. . .

M: Počkej, už toho zase na mě hrneš příliš mnoho. Pověz mi o tom trochu podrobněji. Myslím, že bych mohl zpestřit svoji seminárku nějakým tím modelem.

5.1 Základní myšlenky o modelování

Než se začneme zabývat konkrétními způsoby modelování, proberme ústřední myšlenky, které se k modelování a simulaci váží. Úplně nejdříve si však ujasněme vztah mezi těmito dvěma pojmy. Při modelování vytváříme model. Při simulaci bereme již vytvořený model a uvádíme jej „do pohybu“ a sledujeme jeho chování v různých situacích. Někdy může být smysluplné zabývat se pouze jednou z těchto činností, např. sochu můžeme chápat jako model, se kterým neděláme simulace, simulace dopravních nehod můžeme provádět s reálnými auty (a tedy bez použití modelování). Nicméně v této knize se budeme zabývat vždy modelováním a simulací dohromady a budeme tyto pojmy používat relativně volně.

Modely jsou špatně

Všechny modely jsou špatně. Některé modely jsou užitečné. (G. Box, W. E. Deming)

Základní myšlenka modelování je vyjádřena výše uvedeným citátem (citát je připisován oběma zmíněným autorům). Co ten citát vlastně říká? *Všechny modely jsou špatně.* Model je vždy zjednodušením, abstrakcí reality, jinak by to nebyl model. Model tedy nikdy nemůže být úplně dobře. Vždy se něčím od reality liší. *Některé modely jsou užitečné.* Model může být užitečný právě díky zjednodušením. Dobrý model vybírá důležité aspekty reality a ty nepodstatné skryje, čímž nám pomáhá lépe o realitě uvažovat. Samozřejmě jen některé modely jsou užitečné, zdaleka ne všechny.

Uveďme si konkrétní příklad, který všichni dobře známe: mapa. Mapa je model prostoru. Mapa je špatně, protože je to abstrakce reality: neobsahuje všechny detaily a dochází u ní ke zkreslení. Jak každý z vlastní zkušenosti jistě potvrdí, sebelepší mapa má řadu chyb. I přesto je mapa velmi užitečná, a to z mnoha důvodů: pochopení reality (mapa jako výuková pomůcka), plánování akcí (kterou cestou se mám vydat) nebo usnadnění komunikace (potkáme se na tomto místě).

Souvislosti: Příklad s mapou je často používaný, více jej rozvádí například Holland (1995).

Jednoduchost a účel

Hledej jednoduchost a nevěř jí. (A. N. Whitehead)

Všechno by mělo být tak jednoduché, jak je to jen možné, ale ne jednodušší. (A. Einstein)

Věda může být popsána jako umění systematického přílišného zjednodušení. (K. Popper)

Jeden z hlavních principů při modelování zní: *Nemodelovat systém, modelovat problém.* Aby byl model užitečný, musí mít jasný účel. Pokračujme s příkladem s mapou – máme různé mapy, každou pro specifický účel (např. automapy, cyklomapy, turistické mapy, vodácké mapy), univerzální mapa by byla k ničemu.

Musíme si jasně zvolit účel modelu a potom se snažit udržovat model co nejjednodušší. Jedním z rizik modelování je naivní realismus – snaha udělat model co nejpřesnější a nejpřesnější. V tomto ohledu výkonné počítače modelování občas ztěžují – dříve byl modelář nucen udělat model abstraktní a jednoduchý, dnes mu počítač umožní vytvořit model, který je detailní, složitý, efektně vypadá, ovšem neposkytuje odpověď na žádné otázky.

Snažíme se tedy pracovat s jednoduchými modely, současně však musíme stále pamatovat, že pracujeme pouze s modely, a ne s realitou. Nesmíme zapomínat na zjednodušení, která model nese. Jak praví východní moudrost: *Neplést si prst ukazující na měsíc s měsícem samotným.* Jde o zdánlivě triviální fakt, který však může být zdrojem mnohých problémů a nedorozumění. Například při plánování cesty na horách snadno zapomeneme, že na mapách nejsou bouřky. Podle novinových titulků to vypadá, že zapomináme, že HDP je jen zjednodušeným modelem pro měření vyspělosti státu.

Modelování jako umění

Umění je lež, která nám pomáhá uvědomit si pravdu. (P. Picasso)

S modelováním je to podobné jako s uměním. Dobrý model nereprodukuje skutečnost co nejpřesněji, ale naopak ji záměrně zjednodušuje a tím nám pomáhá pochopit alespoň část komplikované reality. Tato spojitost mezi modelováním a uměním není náhodná. Modelování komplexních systémů totiž není jenom věda, ale do značné míry také umění.

Pro ilustraci uvedme citát z vědecké zprávy Mezinárodního panelu pro klimatické změny (IPCC): „Plně uznáváme, že mnohá z uvedených tvrzení jsou do jisté míry založena na subjektivním vědeckém vnímání a obsahují komunitní a osobní vědomosti. Například pouhý výběr proměnných a procesů, které jsou do modelu zahrnuty, je většinou založen pouze na dojmeh a zkušenostech modelovací komunity.“

5.2 Cíle modelování a simulace

Proč vůbec používáme modely? K čemu nám je simulace? Na tyto otázky není univerzální odpověď, protože modelování a simulaci můžeme použít za mnoha rozmanitými účely.

Návrh a řízení systémů

Všechny stabilní procesy bychom měli pochopit. Všechny nestabilní procesy bychom měli kontrolovat. (J. von Neumann)

Pokud systém sami navrhujeme nebo nad ním máme výraznou kontrolu a dobře mu rozumíme, můžeme použít modelování s cílem porovnat různé možnosti našeho postupu. Při modelování se snažíme o maximální přesnost, simulace by měla věrohodně reprodukovat chování reálného systému. Pomocí simulací zkusíme různé varianty návrhu a vyhodnocujeme zásahy do systému. Tento styl modelování se používá především v technických oborech, např. při konstrukci dopravních prostředků.

Předpovídání chování

Bruslím tam, kde puk bude, nikoliv tam, kde je. (W. Gretzky, odpověď na dotaz ohledně jeho tajemství jako úspěšného hokejového hráče)

Moudrá moucha ví, kam kráčí velbloud. (přísloví)

Další styl modelování spadá do oblasti, kdy systému trochu rozumíme, nemůžeme jej řídit, ale zato by nás opravdu zajímalo, jak se bude vyvíjet v budoucnosti. Typickými příklady jsou počasí, odhad spotřeby (ropy, nápojů) nebo vývoj cen na burze. V těchto případech se pokoušíme pomocí modelu co nejdříve zachytit chování systému – využíváme například data z historie, pomocí kterých model kalibrujeme. Jakmile máme model hotový, využíváme simulace k předpovídání budoucího chování.

Porozumění

Intelektuálové řeší problémy; géniové jim předcházejí. (A. Einstein)

Pokud je předmětem našeho zájmu systém, který nás zajímá, ale moc mu nerozumíme, můžeme využít modelování s cílem porozumět systému a objevovat jeho zákonitosti. Vytváříme modely, které představují naše hypotézy o fungování systému a pomocí simulace zkoumáme, do jaké míry jednotlivé hypotézy odpovídají realitě. Cílem modelování není reprodukovat chování systému přesně, spíše se snažíme přijít na hlavní principy. U komplexních systémů využíváme modelování a simulaci nejčastěji tímto způsobem.

Učení, trénink, zábava

V dobách změny získají Zemi ti, kdo se učí, kdežto ti, kdo jsou učení, zjistí, že jsou perfektně vybaveni zabývat se světem, který již neexistuje. (E. Hoffer)

U výše uvedených způsobů použití modelů je často tvůrce a uživatel modelu tatáž osoba. Modelování však může směřovat i k tomu, abychom model předali k užívání dalším lidem. Typickým příkladem je využití modelu při výuce. Modely mohou

posloužit k předávání myšlenek, k vysvětlení argumentů nebo k propagaci – například fyzický model přesunutého brněnského nádraží, pomocí kterého radní přesvědčují skeptické občany o svém plánu. Práci s modelem můžeme využít jako trénink pro práci s reálným systémem, typickým příkladem jsou simulátory dopravních prostředků. Konečně práce s modelem může často sloužit prostě jako zábava, jak tomu je v případě počítačových her nebo stavebnic.

5.3 Typy modelů

Poté co jsme uvedli stručný přehled cílů modelování, pojďme se podívat, jak můžeme těchto cílů dosáhnout. Existuje celá řada typů modelů, přičemž některé druhy jsou úzce svázány s konkrétním cílem (např. hry s učněním a zábavou), většinu typů modelů však můžeme použít rozličnými způsoby.

Mentální modely

Samo naše myšlení je založeno na (podvědomém) použití mentálních modelů. Realitu nevnímáme přímo, ale prostřednictvím našich smyslů. I samo vnímání už tedy představuje informační filtr. K dalšímu filtrování dochází v mozku, který si zdaleka nepamatuje všechny vjemy. To, co vnímáme jako realitu, tedy zdaleka není opravdová realita, ale jen její velmi zjednodušený model. Veškeré myšlení probíhá s využitím tohoto modelu, rozhodnutí děláme vlastně s využitím analýz a simulací mentálního modelu reality. Používání modelů se tedy nevyhneme – otázkou je pouze, o jaké modely jde.

Mentální modely však používáme i vědomě a záměrně. Například metafory a analogie jsou vlastně modely. Dalším pěkným příkladem jsou karikatury, které sice nepředstavují čistě mentální model, nicméně dobře ilustrují smysl modelů. Proč v době jednoduchého a rychlého fotografování lidé kreslí karikatury, které jsou záměrně „chybné“. Fotografie je daleko lepší model reality než karikatura, co se míry detailu týče. Smysl karikatury tkví ve vypuštění některých aspektů reality a naopak zdůraznění jiných – právě těch, které jsou na dotyčné osobě charakteristické. Tak funguje i dobré modelování – cílem není přiblížit se co nejvíce realitě, ale zdůraznit to, co je důležité.

Fyzické modely

Co se stane, když velký asteroid narazí do Země? Soudě podle realistických simulací za použití palice a běžné laboratorní záby můžeme předpokládat, že to bude docela špatné. (D. Barry)

S fyzickými modely se setkáváme již od dětství. Mnohé hračky (např. autíčka, panenky) jsou vlastně modely, stejně jako většina her, které děti hrají. Tyto modely slouží především k zábavě a k výuce. Fyzické modely jsou však nejen pro děti. Například simulátory dopravních prostředků jsou modely, které se snaží co nejvěrohodněji

napodobit realitu – například interiér simulátoru letadla je věrnou kopií interiéru reálného letadla. Pomocí těchto modelů pak probíhá výuka v bezpečném prostředí.

Fyzické modely se také dlouho užívaly při návrhu systémů, jako jsou stavby či dopravní prostředky (například větrné tunely používané při konstrukci letadel). V současné době se z finančních a časových důvodů pro vlastní návrh místo fyzických modelů používají stále častěji počítačové simulace. Nicméně fyzické modely jsou stále užitečné pro prezentaci návrhů manažerům, politikům či veřejnosti.

Matematické modely

Další typ modelu tvoří matematické rovnice, které vyjadřují stav světa. Matematické modely můžeme dále rozdělit na dvě kategorie. První z nich tvoří popisné modely, které udávají vztah mezi proměnnými v určitém časovém okamžiku, aniž by samy o sobě vysvětlovaly, proč tento vztah platí. Typicky jde o statistické regresní modely, např. vztah mezi HDP a očekávanou délkou života.

Druhou kategorií tvoří dynamické modely, které popisují, jak se mění hodnoty proměnných v čase. Typicky jde o diferenciální rovnice, např. vztah mezi velikostí populace predátora a kořisti nebo vztah mezi poptávkou a nabídkou. S těmito modely pracujeme pomocí exaktní analýzy (proto se jim říká také analytické modely), většinou tak, že se snažíme vyřešit systém rovnic a najít rovnovážnou situaci.

Výpočetní modely

V této knize se podrobně zaměříme pouze na jeden typ modelů, a to na výpočetní modely. V tomto případě je model matematický zápis (např. soustava rovnic) nebo program. Model však nezkoumáme analyticky, ale simulací – výpočtem. Tuto simulaci dostáváme pomocí numerického řešení rovnic nebo spuštěním programu.

Mnohé výpočetní modely lze uvažovat i bez použití počítačů, simulovat je můžeme pomocí tužky a papíru. Ve většině případů bychom se však takto daleko nedostali, typické výpočetní modely mají chování natolik složité, že s tužkou a papírem bychom se dříve upsali, než bychom dostali použitelný výsledek. Výkonné počítače jsou tedy pro analýzu prakticky nezbytné. Spousta modelů, které si ukážeme, je v principu velmi jednoduchá, obsahuje však mnoho interagujících prvků a k provedení simulace je nutné provést mnoho iterací. Proto jsou tyto modely zkoumány až v posledních letech, kdy už jsou běžně k dispozici výkonné počítače použitelné pro automatickou simulaci a analýzu modelů.

5.4 Specifika výpočetních modelů

Než se vrhneme na vlastní využití výpočetních modelů, podívejme se, jak výpočetní modely zapadají mezi další způsoby uvažování o světě.

Výpočetní modely jako třetí cesta

Simulaci pomocí výpočetního modelu můžeme vidět jako třetí cestu, jak zkoumat svět, jako cestu, která je mezi teoretickým deduktivním uvažováním a experimentálním induktivním uvažováním (Axelrod, 1997b). Při deduktivním zkoumání světa používáme zjednodušený model světa a snažíme se o modelu něco exaktně dokázat. Abychom byly schopni exaktně dokazovat, musíme se omezit jen na malé modely. Při induktivním zkoumání světa pracujeme přímo se systémem, nikoliv s modelem. Podnikáme experimenty, měříme výsledky. Můžeme pracovat s velkými systémy, závěry jsou však pouze popisné.

Simulace, podobně jako dedukce, používá modely. Nepokouší se však výsledky exaktně dokazovat. Podobně jako při induktivním zkoumání při použití simulace generujeme data a tato data zkoumáme a popisujeme. Na rozdíl od experimentu data u simulace pocházejí z přesně specifikovaného modelu. Tento přístup nám umožňuje pracovat s reálnějšími modely než v případě dedukce a současně prozkoumávat možnosti, které by za použití klasického experimentu nebyly proveditelné.

Výpočetní modely můžeme vidět jako „někde uprostřed“ i z hlediska abstraktnosti a konkrétnosti. Výpočetní modely jsou totiž současně velmi abstraktní a velmi konkrétní. Jsou abstraktní, protože pracují pouze se symbolickými entitami (čísla uložená v paměti). Fyzické modely jsou proti výpočetním daleko reálnější a konkrétnější. Na druhou stranu ve srovnání s mentálními modely, které jsou mnohdy velmi mlhavé, jsou výpočetní modely dost konkrétní, protože počítač je velmi „tupý“. Abychom mohli model na počítači simulovat, musíme zapsat opravdu přesně, co vlastně má model dělat.

Srovnání matematických a výpočetních modelů

Je daleko lepší mít přibližnou odpověď na správnou otázku než přesnou odpověď na špatnou otázku. (J. W. Tukey)

Modely se pro studium komplexních systémů používají dlouho. Až donedávna se používaly především matematické modely – mají je v oblibě například ekonomové, kteří se s jejich pomocí snaží dodat svým závěrům co největší matematickou rigoróznost.

Podívejme se tedy stručně na rozdíly mezi výpočetními modely s klasičtějšími matematickými modely. Toto srovnání, které je v heslovité podobě uvedeno v tabulce 5.1, ilustrujeme na příkladě modelu trhu.

Matematické modely pracují buď s velmi malým množstvím částí (takže lze analyzovat všechny vztahy), nebo velmi velkým (takže lze pracovat s průměrným chováním). Analýzy se zaměřují především na studium rovnovážných situací a tyto situace jsou schopny popsat velmi přesně. Flexibilita modelů je nízká, protože i malá změna modelu si může vyžádat náročné přepracování celé analýzy. Matematický model trhu tedy většinou předpokládá dva obchodující nebo nekonečný počet obchodujících a cílem analýzy je určit rovnovážnou cenu (poptávka se vyrovná s nabídkou).

Tabulka 5.1: Srovnání matematických a výpočetních modelů (podle Miller, Page, 2007).

	Matematické modely	Výpočetní modely
předmět zájmu	rovnováha	dynamika
přesnost výsledků	vysoká	nízká
flexibilita modelů	nízká	vysoká
počet částí	1, 2, ∞	středně velký
struktura	fixní	proměnlivá
heterogenita	nízká	vysoká
centralizace	vysoká	nízká

Výpočetní modely pracují se středně velkým množstvím částí a zaměřují se spíše na dynamiku chování než na analýzu rovnovážných situací. Modely jsou více flexibilní, změny lze zakomponovat daleko snadněji. Výsledky simulací však většinou nedávají přesné a dokazatelné odpovědi. Výpočetní model trhu může obsahovat například deset obchodníků a cílem analýzy může být třeba sledování dynamiky trhu – jak obchodníci dospějí k výsledné ceně?

Výpočetní modely mohou být na rozdíl od matematických dynamičtější, jejich struktura se může v průběhu vývoje modelu měnit, mohou zahrnovat například adaptaci, učení. Výpočetní modely také umožňují pracovat s větší heterogenitou. U matematického modelu trhu předpokládáme, že mají všichni obchodníci identické znalosti a dokonale racionální chování, ve výpočetním modelu může mít každý obchodník jiné informace a mohou se postupně učit ze zkušeností.

Výpočetní modely mohou být decentralizované, kdežto matematické modely jsou centralizované, i když třeba nepřímo. Například v matematickém modelu trhu s velkým počtem obchodníků předpokládáme, že cena je určena na základě poptávky a nabídky. Ale kdo určuje tuto cenu? Matematický model stanovuje cenu na základě souhrnné znalosti poptávky a nabídky, čímž implicitně předpokládá existenci jakési centralizované autority s všeobecným přehledem. Ve výpočetním modelu můžeme studovat, jak se cena určuje na základě decentralizovaných interakcí.

Výhodou výpočetních modelů je také nižší cena a větší intuitivnost – dobrý matematický model zvládne sestavit a pochopit pouze expert, kdežto výsledky počítačové simulace je většinou možné vysvětlit i laikovi.

Souvislosti: Příklad modelu trhu (matematický i výpočetní) je podrobněji rozebrán v části 13.2.

5.5 Fáze modelování

Zásadní chybou je teoretizovat dřív, než má člověk data. Jinak člověk začne přizpůsobovat fakta teoriím, místo aby přizpůsoboval teorie faktům.

(S. Holmes /A. C. Doyle/)

V další části knihy probereme různé modelovací techniky. Přestože jsou tyto techniky značně rozmanité, základní proces modelování – postup činností, které při modelování provádíme – je ve všech příkladech podobný. Tento proces můžeme rozdělit na šest fází:

1. formulace problému,
2. základní návrh modelu,
3. implementace modelu,
4. verifikace a validace,
5. simulace a analýza,
6. sumarizace výsledků.

Tento seznam je samozřejmě idealizovaný. V praxi nepostupujeme plynule od bodu 1 k bodu 6, ale v případě potřeby se vracíme k předešlým bodům a opakujeme je – modelování je iterativní proces. Přestože je uvedený postup idealizovaný, měli bychom jej znát a žádný z uvedených bodů neopomenout.

Souvislosti: Fáze modelování popisuje detailněji například Sterman (2000) a Grimm a Railsback (2005).

Formulace problému

Vědec není ten, kdo dává správné odpovědi, ale ten, kdo klade správné otázky. (C. Lévi-Strauss)

Jak už jsme zmínili, jeden ze základních principů modelování je: *Nemodelovat systém, modelovat konkrétní problém.* V první fázi modelování tedy jasně formulujeme, jaký problém se snažíme s pomocí modelu řešit a na jaké otázky se pokoušíme odpovědět. Snažíme se problém zachytit co nejkonkrétněji, pokud možno numericky. Určíme časový horizont, ve kterém problém studujeme – jak daleko do minulosti (budoucnosti) potřebujeme uvažovat? Při formulaci problému bereme v potaz prostředky, které máme k dispozici (mimo jiné čas, finance, zkušenosti). Málokdo zvládne zachránit svět v rámci jednosemestrálního projektu.

Uvažme jako příklad téma „cena ropy“. Samo o sobě toto téma není dostatečnou formulací zadání modelu. Podle toho, na co se zaměříme, můžeme dostat naprosto odlišné modely. Pokud se na cenu ropy díváme z pohledu obchodníka na trhu, tak je relevantní zvolit časový horizont v řádu měsíců, zaměřit se na aktuální poptávku, nabídku a třeba válečné konflikty, které ovlivňují nabídku, přičemž neobnovitelnost zdroje nehraje v tomto horizontu téměř žádnou roli. Pokud se na cenu ropy podíváme z pohledu energetické bezpečnosti Evropy, je relevantní zvolit časový interval v řádu let a zahrnout do modelu například umístění a kapacitu jednotlivých nalezišť a ropovodů. Pokud se na cenu ropy podíváme z hlediska závislosti lidstva na neobnovitelném zdroji, je relevantní zvolit časový interval v řádu desítek let a soustředit se v modelu na přechod k alternativním zdrojům.

Základní návrh modelu

V prvních fázích se snažíme udržovat model co nejjednodušší. Používáme nejhrubší úroveň abstrakce dostatečnou pro daný účel a přidáváme detaily, až když je to nutné. Určíme si okraje modelu, tj. vybereme, které prvky budeme modelovat. Zaměřujeme

se především na okraje „do šířky“, tj. co vše bude v modelu zohledněno, rámcově určujeme také okraje „do hloubky“, tj. jak detailně budou jednotlivé prvky zohledněny.

Určujeme hlavní prvky modelu, části a vztahy mezi nimi. Používáme kvalitativní vztahy (co s čím souvisí), nikoliv kvantitativní (jak přesně to souvisí). Které prvky systému mají nejdůležitější vztah ke studovanému problému? Které děje ovlivňují chování systému?

Pokračujme s příkladem o ceně ropy. Řekněme, že jsme si vybrali dlouhodobý časový horizont. Mezi hlavní části modelu by v tomto případě patřily asi zásoby ropy, velikost populace, stav ekonomiky, stav technologií (alternativní zdroje) a samotná cena ropy. Vymezení těchto oblastí určuje okraje do šířky. Určení okrajů do hloubky znamená, jak detailně budeme jednotlivé prvky reprezentovat. Musíme se například rozhodnout, zda budeme uvažovat globální populaci (ekonomiku), nebo zda rozlišíme různé kontinenty či dokonce jednotlivé země. Dále musíme určit vztahy. Zjevně například velikost populace ovlivňuje zásoby ropy. Chceme ale třeba mít v modelu i opačnou vazbu, tj. ovlivnění velikosti populace zásobami ropy?

Implementace modelu

Vybereme modelovací přístup a nástroj, který použijeme. Určíme reprezentaci klíčových prvků a dějů. Doplňme další části modelu, uzavřeme model. Použití výpočetních modelů má tu výhodu, že nás nutí doplnit všechny části modelu, přesně vyjádřit všechny vlastnosti a souvislosti. V mentálních modelech máme často skryté předpoklady, které si sami neuvědomujeme. Počítačový model, aby byl spustitelný, musí být kompletní, a musíme tedy jasně formulovat všechny předpoklady.

Posledním krokem implementace modelu je určení hodnot parametrů, doplnění kvantitativních informací. Tyto informace určujeme na základě pozorování, statistických měření nebo prostého odhadu.

Kdybychom pokračovali s naším příkladem, museli bychom nyní určit přesný způsob reprezentace výše zmíněných položek a vztahů mezi nimi, například konkrétní rovnice pro čerpání zásob ropy a pravidla pro přechod na alternativní zdroje. Numerická data bychom mohli doplnit podle historických tabulek.

Verifikace a validace

Jakmile máme spustitelný model, musíme ověřit, zda je opravdu vhodný pro zodpovězení vytyčených otázek – musíme model verifikovat a validovat. Validace je ověření, že návrh modelu opravdu reflektuje chování reálného systému, tj. ověření vztahu mezi realitou a abstraktním návrhem. Můžeme například ověřit, že když vypneme pravidlo pro přechod na alternativní zdroje, tak dojde k rychlejšímu vyčerpání ropy.

Verifikace je ověření, že model opravdu dělá to, co si myslíme, že by měl dělat, tj. ověření vztahu mezi abstraktním návrhem modelu a jeho konkrétní implementací. Řekněme, že jsme pro náš model vymysleli pravidlo přechodu na alternativní zdroje,

v rámci verifikace kontrolujeme, zda implementace pravidla odpovídá naší představě o fungování pravidla.

Verifikace je v podstatě „inženýrská“ záležitost, dá se provádět vcelku exaktně a pomocí rigorózních postupů (které jsou nicméně nad rámec této knihy). S validací je to náročnější, protože ze základního principu „všechny modely jsou špatné“ plyne, že model nikdy nemůže být zcela validní (odpovídající realitě). Validace je tedy vždy do jisté míry subjektivní a spíše než správností modelu se zabývá jeho užitečností.

Simulace a analýza

Pokud se nám podaří vyrobit model, o kterém jsme přesvědčeni, že je pro naše účely vhodný, důkladně jej analyzujeme. Cíle analýzy závisejí na konkrétním problému, typicky však spadají pod následující otázky. Jakou roli hrají jednotlivé prvky modelu? Které prvky modelu mají největší vliv na jeho chování? Jaké je chování modelu za změněných (měnících se) podmínek?

Pro příklad s ropou můžeme studovat třeba otázky: Jak se liší vývoj situace při různých pravidlech přechodu na alternativní zdroje? Jaký vliv má na vývoj ceny velikost populace (případně populační dynamika)? Dokážeme pomocí modelu ilustrovat různé scénáře, například plynulý přechod na alternativní zdroje a prudký kolaps ekonomiky? Které parametry modelu mají klíčový vliv na to, jaký scénář převáží?

Sumarizace výsledků

Studujeme výsledky, pokoušíme se o formulaci odpovědí na původní otázky. V případě potřeby se vracíme k předchozím bodům. Příklady otázek, které se snažíme zodpovědět:

- Podařilo se najít odpověď na původní otázku? Splňuje model účel?
- Plynou z modelování a simulace nějaké závěry a poučení? Jaké?
- Jak můžeme model dále využít?
- Je potřeba model rozšířit? Proč? Jaké rozšíření by bylo vhodné?

Souvislosti: Metody simulace a analýzy jsou detailně rozebrány v kapitole 10. V kapitole 15 jsou na konkrétním velkém příkladu ilustrovány všechny fáze modelování.

5.6 Shrnutí

- Všechny modely jsou špatné. Některé modely jsou užitečné.
- Nemodelovat systém, modelovat problém.
- Neplést si prst ukazující na měsíc s měsícem samotným. Nezaměňovat model a realitu.
- Modelování, stejně jako umění, je lež, která nám pomáhá lépe pochopit realitu.
- Simulaci můžeme chápat jako třetí cestu mezi experimentem (indukcí) a analýzou (dedukcí).

-
- Modelování a simulace mohou mít mnoho cílů, např. porozumění systému, formalizace hypotéz, předvídání chování, návrh systémů, řízení systémů, učení, trénink, zábava.
 - Modely používáme neustále. Otázka tedy není, jestli používat modely, ale jaké modely používat.
 - Jeden způsob třídění modelů je na mentální, fyzické, matematické a výpočetní modely.
 - Proces modelování můžeme rozčlenit do několika základních fází. Modelování je iterativní proces.

Část II

Metody modelování a simulace

Druhá část je již techničtější než část první a obsahuje přehled konkrétních modelovacích technik. Techniky jsou zde ilustrovány pouze na malých příkladech – pro možnost srovnání používáme v této části převážně příklady z oblasti populační dynamiky. Větší příklady jsou rozebrány v třetí části knihy.

Než se vrhneme na jednotlivé modelovací přístupy, podívejme se na dva základní přístupy k výpočetním modelům a na to, jak do tohoto rozdělení zapadají jednotlivé přístupy. K modelování můžeme přistupovat shora nebo zdola. Při modelování shora se díváme na souhrnné veličiny, zajímáme se o celkovou strukturu systému a explicitně pojmenováváme zpětné vazby. Při modelování zdola se díváme na jednotlivé části, definujeme pravidla jejich chování a vývoj celku dostáváme jako důsledek. Následující tabulka shrnuje (v zjednodušené podobě) základní rozdíly mezi těmi dvěma přístupy:

	Modelování shora	Modelování zdola
základní bloky	sumární veličiny	jednotlivci a jejich interakce
zpětné vazby	explicitně vyjádřeny	modelovány nepřímo
centrum zájmu	struktura systému	pravidla pro chování agentů
přístup	deduktivní: od struktury k chování	induktivní: od chování jednotlivců k chování celku
model v čase	fixní	agenti mohou být adaptivní
čas	většinou spojitý	většinou diskretní

Matematické modelování a systémová dynamika (kapitola 6) představují typické modelovací přístupy shora. Stav systému vyjadřujeme pomocí sumárních proměnných (např. počet králíků), chování systému pomocí rovnic (např. jak závisí počet králíků na počtu lišek). Zpětné vazby vyjadřujeme v modelu explicitně, modely mají často blízko k zpětnovazebním diagramům popsaným v kapitole 4.2.

Buněčné automaty a modelování pomocí agentů (kapitola 7) jsou naopak typické modelovací přístupy zdola. Definujeme jedince (políčka na pravidelném plánu nebo pohyblivé agenty) a pravidla jejich chování (např. králík se náhodně pohybuje, požírá trávu, pokud je dost sytý, tak se množí). Model pak sestává z velkého množství jedinců spuštěných souběžně.

Modelování myšlení a vývoje (kapitola 8) představuje modelování zdola, speciálně s důrazem na modelování jednotlivce a jeho pravidel. My se zaměříme na modelování myšlení a vývoje především s aplikovatelností na rozšíření modelů s agenty.

Kapitola o komplexních sítích (kapitola 9) představuje trochu jiný typ modelování než ostatní kapitoly. Snažíme se zachytit především (statickou) strukturu systému a tuto strukturu můžeme využít buď pro samostatnou analýzu, nebo jako podklad pro jiné typy modelů (např. modely s agenty).

Na závěr této části se zabýváme metodami pro analýzu modelů (kapitola 10) – základní metody jsou do velké míry podobné pro všechny uvedené modelovací metody.

6 Matematické modelování a systémová dynamika

M: Posledně, jak jsi vykládal o modelování, to bylo zajímavé, ale bylo to obecné povídání a příliš mi to nepomohlo, abych si udělal vlastní model s králíky. Nechceš mi ukázat konkrétní přístup k modelování?

S: Dobře. Můžeme začít s matematickým modelováním – to má ostatně nejdelší tradici. Navíc, když tě zajímají králíci, hodí se začít s Fibonacciho rovnicí. Stav systému, tedy počet párů králíků, v čase t vyjádříme jako X_t . Předpokládáme, že v každém roce se každému páru králíků, kteří už jsou alespoň dvouletí, narodí právě jeden pár mladých králíčků. Navíc předpokládáme, že králíci jsou nesmrtelní. Takže pro počet králíků dostáváme rovnici: $X_t = X_{t-1} + X_{t-2}$. Navíc doplníme počáteční počty králíků, řekněme $X_0 = 1$ a $X_1 = 1$, a máme velmi jednoduchý model hotový.

M: To je tedy opravdu hodně zjednodušený model, ale budiž. Co teď s tím? Teď musíme rovnici vyřešit a vyjádřit X_t jako funkci t ?

S: To je možný postup a v tomto případě bychom asi uspěli. Jakmile ale model rozšíříme a přidáme tam pár proměnných a rovnic navíc, případně ještě k tomu použijeme spojitý čas místo diskrétního, tak už ty rovnice ručně nevyřešíme. . .

M: Takže jsme nahraní? To jsme si moc nezamodelovali.

S: Kdepak. Tady přicházejí na řadu počítače. Prostě si ty vztahy odsimulujeme krok po kroku. V případě spojitých modelů vypočteme přibližné řešení numericky třeba pomocí Eulerovy metody.

M: Pomocí čeho?

S: Prostě místo toho, abychom našli obecné řešení těch rovnic pro libovolné t , vypočítáme numericky přibližné řešení jen pro konkrétní časový interval. Kdybychom to měli dělat ručně, buď se upočítáme k smrti, nebo najdeme jen velmi nepřesné řešení. Díky počítači, který zvládá dělat rychle spoustu elementárních operací, se k řešení přiblížíme snadno a rychle.

M: Dobrá, dobrá, takže rovnice nemusím řešit, to za mě udělá počítač. Ale pořád je ještě musím napsat. To taky není úplně moje silná stránka. Nemohl by za mě počítač psát i rovnice?

S: Do jisté míry ano – k tomu slouží přístup zvaný systémová dynamika. Je to vlastně taková grafická nástavba nad těmi rovnicemi. Vyjádříš proměnné a vztahy pomocí diagramů a počítačový nástroj za tebe rovnice automaticky vygeneruje. Nicméně část těch rovnic musíš i tak doplnit ty. Ale neboj, když se budeš držet osvědčených postupů, není na tom nic komplikovaného.

6.1 Matematické modelování pomocí rovnic

Matematické modelování je založeno na následujících principech:

1. Stav systému vyjádříme pomocí stavových proměnných, což jsou proměnné kódující souhrnné informace, například velikost populace králíků, počet aut, celkový zisk firmy nebo míra inflace.
2. Chování systému vyjádříme pomocí rovnic, ve kterých vystupují stavové proměnné.

Rovnice udávají, jak se mění hodnota proměnných. Tuto změnu můžeme provádět buď v diskrétních časových krocích, nebo spojitě – podle toho rozlišujeme základní typy matematických modelů. V obou případech můžeme chování modelu definovaného rovnicemi dále zkoumat dvěma způsoby. Za prvé můžeme použít exaktní matematickou analýzu problému, pomocí níž najdeme obecné řešení rovnic nebo ekvilibrium systému, tj. hodnoty proměnných, pro které se chování modelu ustálí. Za druhé můžeme použít simulaci – určíme počáteční hodnoty proměnných a další chování modelu určíme numerickým výpočtem.

Všechny tyto možnosti pro názornost ilustrujeme na jednoduchém příkladě populačního růstu.

Souvislosti: Detailnější popis matematického modelování za použití současných matematických softwarových nástrojů (např. Maple) dávají například Barnes a Fulford (2002) a Ellner a Guckenheimer (2006).

Diskrétní čas a rekurentní rovnice

Při použití diskrétního času udávají rovnice hodnotu proměnných v časovém okamžiku $t + 1$ v závislosti na hodnotě proměnných v čase 0 až t . Takovéto rovnice se nazývají rekurentní rovnice. Pokud máme zadány počáteční hodnoty proměnných (v čase 0), hodnoty proměnných můžeme vypočítat přímočaře dosazením.

Nejznámější příklad tohoto typu je známá Fibonacciho posloupnost, která popisuje idealizované množení králíků. Na začátku máme 1 pár nesmrtelných králíků. Jakmile králíci dorostou do věku 2 let, začnou plodit mladé (1 pár zplodí za rok

1 pár mladých). Označme velikost populace v čase t jako X_t . Uvedené předpoklady můžeme vyjádřit pomocí následující rekurentní rovnice:

$$X_{t+1} = X_t + X_{t-1}$$

K dokončení modelu ještě musíme určit počáteční hodnoty: $X_0 = 1, X_1 = 1$. Pro tento model je možné najít explicitní řešení, tj. řešení, které vyjadřuje X_t přímo v závislosti na t :

$$X_t = \frac{\phi^t - (1 - \phi)^t}{\sqrt{5}}, \text{ kde } \phi = (1 + \sqrt{5})/2$$

Detaily způsobu získání řešení zde nebudeme rozebírat – je to sice zajímavý matematický problém, nicméně z pohledu modelování je naprosto dostatečné získat hodnoty výpočtem pomocí dosazení: 1, 1, 2, 3, 5, 8, 13, 21, 34, 55 atd.

Z uvedených analýz vidíme, že v modelu se králíci množí exponenciálně rychle a jejich počet roste nade všechny meze. Takové chování samozřejmě není realistické, žádná populace se nemůže množit nade všechny meze. V modelu, který zachycuje Fibonacciho posloupnost, máme pouze pozitivní zpětnou vazbu (čím víc králíků, tím víc mladých), ale chybí nám korigující negativní zpětná vazba (limit prostředí). Zkonstruujme tedy mírně pozměněný model, který zahrne i kapacitu prostředí (takzvaná logistická rovnice):

$$X_{t+1} = rX_t(1 - X_t/K)$$


Parametr r udává základní míru reprodukce populace – čím větší r , tím rychleji populace roste. Parametr K udává kapacitu prostředí. Jakmile se velikost populace přiblíží ke kapacitě prostředí, člen $1 - X_t/K$ klesne a velikost populace přestane růst nebo se i začne zmenšovat.

Alternativně můžeme stejný model odvodit z předpokladu, že míra porodnosti je nezávislá na velikosti populace, kdežto míra úmrtnosti závisí lineárně na velikosti populace (čím větší populace, tím větší konkurence a tím větší šance, že jedinec zemře). Tento předpoklad můžeme vyjádřit následovně (p je míra porodnosti, u_t je míra úmrtnosti):

$$X_{t+1} = pX_t - u_tX_t, u_t = uX_t$$

Což je ovšem totéž jako předchozí rovnice, pokud dáme $p = r, u = r/K$.

Logistická rovnice ilustruje princip, se kterým se u komplexních systémů setkáváme často: jednoduchá pravidla mohou generovat složitá chování. Jde sice o velmi jednoduchou rovnici, její chování je však složité, přesněji řečeno, její chování závisí složitým způsobem na poměru parametrů r a K . Obr. 6.1 ukazuje různá chování tohoto jednoduchého modelu v závislosti na hodnotě parametrů – vidíme, že chování se může ustálit, pravidelně oscilovat, ale také skákat naprosto chaoticky. Chování logistické rovnice je dobře prozkoumáno – zabývá se jím teorie chaosu – k našemu



Obr. 6.1: Logistický růst populace, chování modelu pro $X_0 = 0,1$; $K = 1$ a tři různé hodnoty parametru r .

tématu se však váže jen okrajově, a proto se jím nebudeme podrobněji zabývat. Z hlediska modelování plyne z této analýzy jedno poučení: složité chování se může objevit u jednodušších modelů, než bychom čekali.

Souvislosti: Logistickou rovnicí a její souvislosti s teorií chaosu rozebírá např. Peitgen et al. (1992). Logistická rovnice má také spojitost s ekologickým konceptem r-strategie a K-strategie (názvy těchto strategií jsou odvozeny právě od parametrů v modelu). Těmito strategiemi se zabývá jeden z projektů uvedených v příloze D.

Spojité čas a diferenciální rovnice

V některých případech nelze čas jednoduše rozdělit na diskrétní kroky. Typickým příkladem může být přítok a odtok vody z nádoby, ale i v případě modelování populací je rozdělení na diskrétní kroky problematické, protože populační dynamiku lze málokdy rozdělit na striktně oddělené generace. Jedinci se většinou rodí a umírají průběžně. Proto používáme spojitý čas a modelování pomocí diferenciálních rovnic.

Čtenář, který není seznámen s diferenciálními rovnicemi, bude v následující pasáži možná mírně ztracen. Detailní pochopení této pasáže však není zásadní pro porozumění dalším kapitolám a pro základní pochopení by mělo stačit číst výraz dX/dt jako „změna hodnoty proměnné X v čase t “.

Pro ilustraci uvážíme opět jednoduchý model pro růst populace, kde je velikost populace vyjádřena proměnnou X . Základní verze modelu vypadá takto (slovně vyjádřeno):

$$\text{změna velikosti populace} = \text{počet narození} - \text{počet úmrtí}$$

Pro začátek předpokládejme, že počet narození i úmrtí je úměrný pouze velikosti populace a že míra porodnosti p i míra úmrtnosti u jsou nezávislé na velikosti populace. Dostáváme tedy diferenciální rovnici:

$$dX/dt = pX - uX$$

Tuto rovnici můžeme upravit pomocí míry reprodukce $r = p - u$ na:

$$dX/dt = rX$$

Tato diferenciální rovnice je jednoduchá a můžeme ji analyticky vyřešit (způsob řešení však opět nebudeme rozebírat, protože pro nás není zásadní). Řešením je funkce:

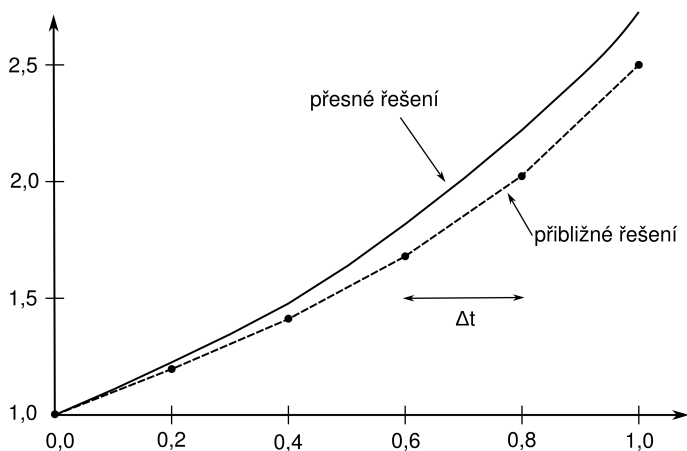
$$X(t) = X(0)e^{rt}$$

Velikost populace tedy exponenciálně roste nebo klesá (podle toho, zda je r kladné, nebo záporné). Realističtějšího chování modelu můžeme dosáhnout stejným způsobem jako pro diskrétní model, tj. pomocí míry úmrtnosti závislé na hustotě, respektive pomocí kapacity prostředí:

$$dX/dt = rX(1 - X/K)$$

Řešení této diferenciální rovnice je:

$$X(t) = K/(1 + (K/X(0) - 1)e^{-rt})$$



Obr. 6.2: Přesné řešení a přibližné řešení diferenciální rovnice $dx/dt = x$, přibližné řešení je získáno Eulerovou metodou za použití $\Delta t = 0, 2$.

Tato křivka má podobný průběh jako diskretní verze pro malé hodnoty r (tedy v případě, kdy dochází k čisté konvergenci).

Numerické řešení diferenciálních rovnic

V uvedených příkladech byly diferenciální rovnice natolik jednoduché, že umíme najít řešení analyticky. Ve složitějších případech to však možné není, nebo je to velmi náročné. Proto používáme numerické řešení diferenciálních rovnic, které nám dává řešení sice jen přibližné, pro účely modelování však většinou plně dostačující.

Numerické řešení neprovádíme ručně, ale používáme k tomu softwarové nástroje (viz příloha C). Modelář by však měl mít základní představu o fungování numerických metod řešení diferenciálních rovnic a o významu volených parametrů, protože výsledky, které pomocí numerického řešení dostaneme, mohou být závislé na použité metodě a nastavení parametrů.

Numerické metody jsou založeny na diskretizaci. Čas rozdělíme na rovnoměrné intervaly délky Δt a výpočty provádíme pouze v těchto diskretních krocích. V bodech $t_n = t + n \cdot \Delta t$ počítáme funkční hodnoty podle diskretizované verze diferenciální rovnice (viz obr. 6.2). Nejjednodušší metodou výpočtu je Eulerova metoda, jejíž základní princip si můžeme představit tak, že výraz dt nahradíme Δt , který určuje délku diskretního kroku. Existují i sofistikovanější metody výpočtu (např. metody typu Runge-Kutta), které při výpočtu provádějí více operací, ale jsou o hodně přesnější. Obecně platí, že se zmenšujícím se Δt metody konvergují k přesnému řešení, ovšem čím menší je Δt , tím je simulace výpočetně (a tedy i časově) náročnější.

Nástroje pro numerické řešení rovnic umožňují volbu metody řešení a délky intervalu Δt . Při nastavení těchto parametrů zohledňujeme následující principy:

- Zvolený diskretní krok Δt by měl být nejvýše polovina nejkratšího intervalu vyskytujícího se v modelu.
- Vždy vyzkoušíme simulaci s několika různými hodnotami Δt a ověříme, zda jsou získané výsledky stabilní.
- Na čistě spojitých modelech upřednostňujeme metodu Runge-Kutta, protože je přesnější. Eulerova metoda je robustnější v případě modelů, které kombinují diskretní a spojitě prvky.

Souvislosti: V kapitole 10 je uveden příklad ukazující, jak velký vliv může mít volba parametru Δt .

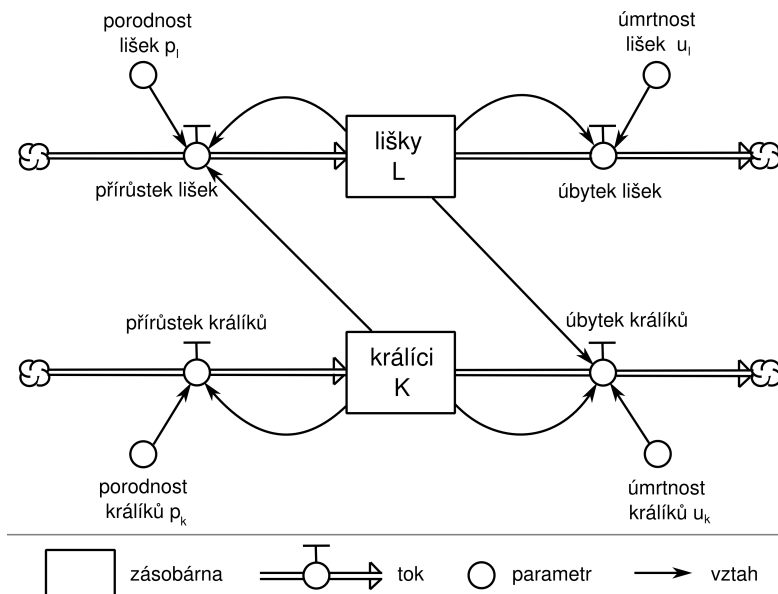
6.2 Systémová dynamika

Pro oblast, kterou v této knize označujeme jako „systémová dynamika“, se používá více různých výrazů (viz slovníček v příloze A). Jednotlivé výrazy mají drobné významové rozdíly, nicméně těmito rozdíly se nebudeme zabývat a zaměříme se na hlavní principy. Systémovou dynamiku můžeme považovat za grafickou nadstavbu nad matematickým modelováním pomocí diferenciálních rovnic. Postup modelování je následující:

1. Graficky vyjádříme základní vztahy v systému. Tyto vztahy v principu odpovídají zpětnovazebním diagramům, které jsme rozebírali v kapitole 4.
2. Na základě grafického diagramu modelovací nástroj automaticky vygeneruje základní diferenciální rovnice.
3. Ručně doplníme zbývající rovnice a hodnoty parametrů.
4. S pomocí nástroje provádíme simulace modelu.

Příklad jednoduchého systémového modelu je na obr. 6.3. Model zachycuje vztahy mezi populacemi lišek a králíků (realističtější by bylo mluvit o zajících, nicméně budeme se držet králíků, aby v knize nevystupovalo příliš mnoho různé zvěře). Jde o velice zjednodušený model, ve kterém předpokládáme, že lišky žerou pouze králíky a králíci umírají pouze tehdy, když je sežere liška. Populace lišek i králíků jsou zachyceny jednou proměnnou, která udává počet jedinců v populaci. V modelu je zahrnut příbytek a úbytek velikosti populací, přičemž příbytek lišek (úbytek králíků) závisí na počtu setkání lišek a králíků (tj. na velikosti obou populací), úbytek lišek (příbytek králíků) závisí pouze na velikosti populace lišek (králíků). Obrázek vyjadřuje přítomnost závislostí, nikoliv jejich charakter. Abychom mohli model simulovat, musíme závislosti přesně specifikovat a určit konkrétní hodnoty parametrů.

Souvislosti: Rozsáhlý úvod do systémové dynamiky s orientací na manažery, obchod poskytuje Sterman (2000), s orientací na environmentální studia pak například Deaton a Winebrake (1997). Manuály nástrojů pro systémovou dynamiku (např. Stella) často obsahují i stručný teoretický úvod, ze kterého lze rychle načerpat základní informace.



Obr. 6.3: Příklad zakreslení modelu v systémové dynamice.

Základní prvky grafického znázornění

Prvky graficky vyjádřeného modelu rozdělujeme do několika tříd a každou z nich zakreslujeme specifickým způsobem. V tabulce 6.1 jsou uvedeny příklady popsanych pojmů.

Zásobárny, které značíme obdélníkem, jsou „podstatná jména“ v modelu, jsou to části systému, kde se něco akumuluje. Obsah zásobárny lze číselně vyjádřit a v čase může stoupat a klesat. Pokud si představíme systém zmražený v určitém okamžiku, má zásobárna (téměř vždy) nenulovou hodnotu.

Toky jsou „slovesa“ v modelu, jsou to aktivity, které určují hodnotu zásobáren v čase, tj. určují, zda obsah zásobárny narůstá, nebo klesá. Pokud si představíme systém zmražený v určitém okamžiku, tak toky mají nulovou hodnotu. Toky mohou být jednosměrné i obousměrné a značíme je dvojitou šipkou, která znázorňuje, odkud kam tok směřuje. Na každém toku je „ventil“, který v závislosti na parametrech a stavu zásobáren určuje velikost toku. Obláček využíváme, pokud zdroj nebo cíl toku leží mimo okraje modelu (např. v uvedeném modelu se nezabýváme tím, co se stane s liškou poté, co zemře).

Parametry určují tempo, s jakým dochází ke změně obsahu zásobárny vlivem toků. Jsou to často vnější proměnné systému, tj. prvky, jejichž chování přímo nemodelujeme a pouze na základě pozorování či úvahy určíme jejich hodnotu. Parametry značíme kolečkem. Všechny uvedené prvky propojujeme šipkami, které udávají vztahy – co s čím souvisí.

Tabulka 6.1: Příklady základních prvků.

Zásobárna	Tok	Parametr
populace	narození, úmrtí, emigrace	porodnost, úmrtnost, míra emigrace
peníze na účtu	úroky, transakce	úroková míra
teplota	ohřívání, ochlazování	tepelná kapacita
podíl na trhu	noví zákazníci	náklady na reklamu, kvalita výrobku

Vyjádření pomocí rovnic

Jak jsme již uvedli, systémové modely jsou v podstatě systémy diferenciálních rovnic. Uvedené rozdělení do různých stavebních prvků slouží „pouze“ k lepšímu modelování a ke grafickému znázornění modelů. Na příkladě lišek a králíků ukážeme, jak přejdeme od grafického ztvárnění k rovnicím.

Abychom model dokončili, musíme ke grafickému vyjádření dále doplnit:

- počáteční hodnoty zásobáren, tj. počáteční hodnoty proměnných K a L ,
- hodnoty parametrů, tj. hodnoty p_l, p_k, u_l, u_k ,
- rovnice pro velikost toků, v našem případě jednoduše vynásobíme hodnoty, na kterých daný tok závisí:
 - příbytek lišek = $p_l K L$,
 - příbytek králíků = $p_k K$,
 - úbytek lišek = $u_l L$,
 - úbytek králíků = $u_k K L$.

Při zadávání rovnic dodržujeme konvenci, že tok závisí právě na těch prvcích, ze kterých do něj vede šipka. Vztah se snažíme vyjádřit co nejjednodušším matematickým vzorcem (typicky násobením jako ve výše uvedeném případě). Pokud neumíme vyjádřit závislost pomocí jednoduchého matematického vztahu, můžeme použít závislost vyjádřenou grafem (zadáme několik hodnot, zbytek grafu se interpoluje úsečkami).

Nyní nám chybí už pouze rovnice pro výpočet hodnoty zásobáren (tj. proměnných K a L). Tyto rovnice můžeme vygenerovat automaticky, protože obecně platí:

$$\text{změna hodnoty zásobárny} = \text{vstupní toky} - \text{výstupní toky}$$

Pro náš model tedy dostáváme:

$$dL/dt = p_l K L - u_l L$$

$$dK/dt = p_k K - u_k K L$$

Souvislosti: Uvedený model je základní pro typ lovec a kořist. Nazývá se Lotka-Voltera model a jde o jeden z prvních modelů studovaných v oblasti populační dynamiky. K tomuto modelu se vrátíme ještě v kapitole 10, kde podrobněji analyzujeme jeho chování. Dalším jednoduchým příkladem podobného typu je model epidemie uvedený v kapitole 11.2. Rozsáhlejší příklad použití systémové dynamiky je popsán v kapitole 15.

6.3 Základní vzory chování

Při mnoha činnostech platí, že je užitečné držet se osvědčených vzorů. Dobrý výsledek většinou nevznikne díky úžasným novým základním prvkům, ale díky dobré kombinaci osvědčených dílů (viz například stavba domu). Tento princip platí i při modelování. Dobré modely nevznikají díky složitým kombinacím vztahů mezi proměnnými, ale díky kombinaci základních vzorů chování.

Zkušenosti ukazují, že existuje pět základních vzorů chování, které v modelech pravidelně potřebujeme zachytit. Tyto vzory chování zachycuje obr. 6.4, na kterém jsou také uvedeny jejich diagramy v systémové dynamice. Nyní uvedeme příklady jednotlivých vzorů a jejich základní vlastnosti.

Lineární vývoj Příklady lineárního růstu a poklesu jsou například stavění železniční trati stabilním tempem nebo fixní čerpání neobnovitelného zdroje. Ke změně dochází konstantní rychlostí, není zde žádná zpětná vazba. Pomocí rovnic můžeme tuto závislost vyjádřit následovně:

- diskrétní rovnice: $X_t = X_{t-1} + k$,
- diferenciální rovnice: $dX/dt = k$.

V tomto případě je explicitní řešení zřejmé: $X_t = X_0 + kt$, resp. $X(t) = X(0) + kt$.

Exponenciální vývoj Příklady exponenciálního růstu a rozpadu jsou populační růst při neomezených zdrojích a samovolný rozpad jaderného materiálu. Rychlost změn je úměrná velikosti zásobárny. Systém je tedy řízen pozitivní zpětnou vazbou. Pomocí rovnic můžeme vyjádřit tento vztah následovně:

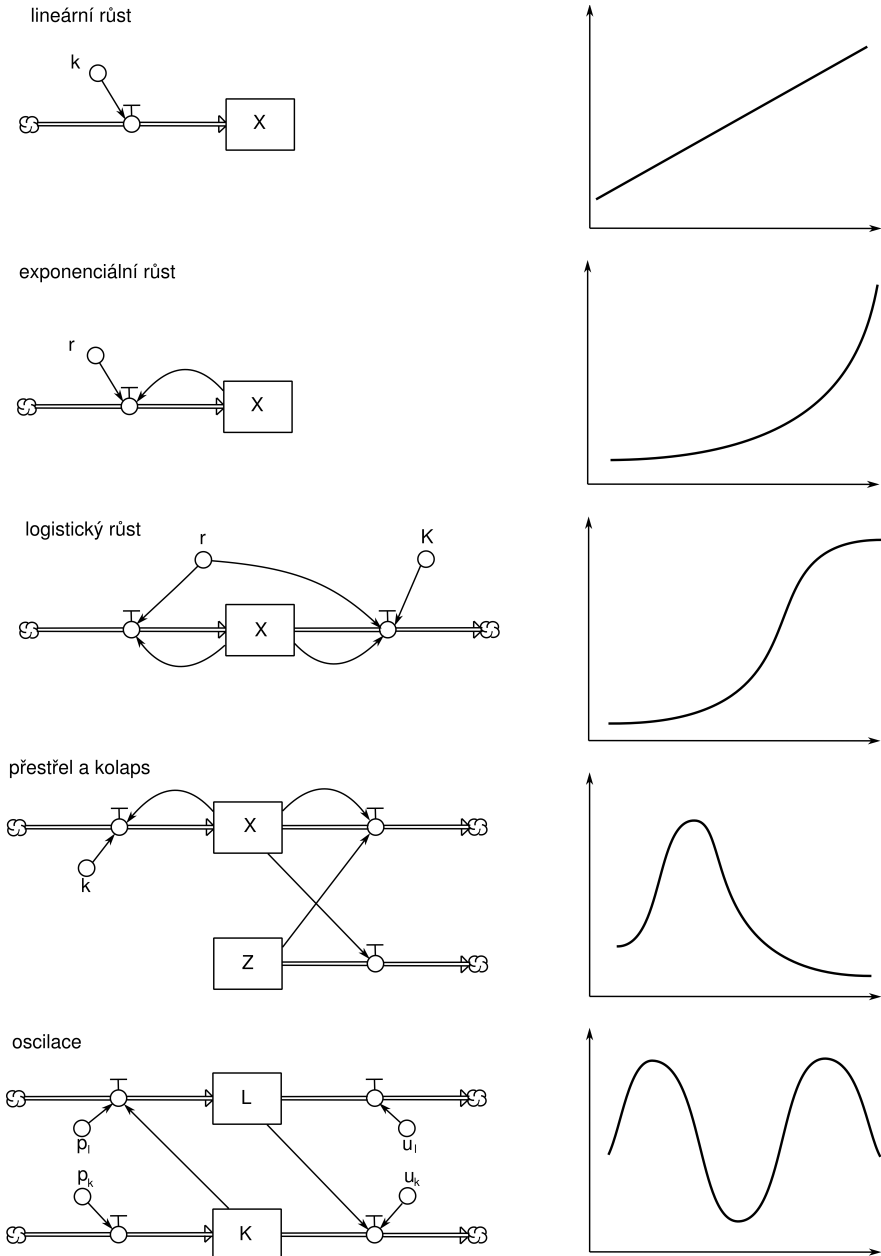
- diskrétní rovnice: $X_t = kX_{t-1}$,
- diferenciální rovnice: $dX/dt = rX$.

Explicitní řešení je opět snadno odvoditelné: $X_t = X_0 k^t$, resp. $X(t) = X(0) \cdot e^{rt}$.

Logistický vývoj Příklady logistického růstu jsou populační růst s fixními zdroji, šíření nákazy nebo informací. V první fázi dochází k exponenciálnímu růstu, který je následován přibližováním k rovnováze (kapacitě K). Jde o kombinaci pozitivní a negativní zpětné vazby. Rovnice pro logistický vývoj jsme rozebrali v části 6.1.

Přestřel a kolaps Příklady chování typu přestřel a kolaps jsou populační růst s neobnovitelnými zdroji a epidemie smrtelné nemoci. Máme dvě zásobárny, jedna z nich je neobnovitelná, druhá na ní závisí a spotřebovává ji. Jde o kombinaci pozitivní a negativní zpětné vazby. Vyjádření pomocí diferenciálních rovnic už je v tomto případě komplikované a nerozebíráme jej. Rozsáhlý model s dynamikou přestřel a kolaps je uveden v kapitole 15.

Oscilace Příklady oscilace jsou systémy lovec a kořist, konzument a obnovitelný zdroj nebo regulace teploty. Jde o dvě vzájemně závislé zásobárny, které jsou spojeny negativní zpětnou vazbou se zpožděním. Tento typ závislosti jsme viděli na příkladě lišek a králíků v předchozí části. Základní instance tohoto typu závislosti je ještě jednodušší než v uvedeném příkladě. Vystačíme s následujícími diferenciálními rovnicemi (používáme stejné značení jako u příkladu s liškami a králíky):



Obr. 6.4: Ilustrace základních vzorů chování.

$$dL/dt = p_l K - u_l$$

$$dK/dt = p_k - u_k L$$

Rovnovážný stav pro tento model je $L = \frac{p_k}{u_k}$, $K = \frac{u_l}{p_l}$. Pokud je systém mimo rovnovážný stav, tak okolo něj osciluje.

Souvislosti: V příloze D jsou rozepsány náměty na praktická cvičení s těmito základními typy modelů.

6.4 Shrnutí

- Tato kapitola se zabývá modelováním „shora“ – používáme sumární proměnné, celkové vztahy a explicitní vyjádření zpětných vazeb.
- Základním přístupem tohoto typu je modelování matematické, při kterém přímo píšeme rovnice vyjadřující závislosti mezi proměnnými.
- Systémová dynamika je grafická nadstavba nad matematickým modelováním. Grafické rozhraní a návrhové vzory nám umožňují jednodušeji zapisovat rovnice.
- Teoreticky můžeme modely zkusit řešit analyticky. To je však možné jen pro velmi jednoduché modely.
- Prakticky používáme simulaci, která spočívá v numerickém, přibližném řešení zadaných rovnic pro konkrétní počáteční podmínky. Výsledkem simulace jsou grafy znázorňující průběh hodnot proměnných v čase.
- Existuje několik základních vzorů chování: lineární růst, exponenciální růst, logistický vývoj, přestřel a kolaps, oscilace. Složitější chování se snažíme modelovat pomocí kombinace těchto základních vzorů.

7 Buněčné automaty a modelování založené na agentech

M: Tak jsem zvládl udělat pomocí rovnic pár jednoduchých modelů s králíky. Ale teď jsem se zasekl. Chtěl bych přidat do modelu i rozmístění v prostoru. Přišlo by mi zajímavé ukázat, jak pohyb králíků souvisí s rozmístěním potravy a vhodných úkrytů.

S: Na to se matematické modelování ani systémová dynamika moc nehodí. V takovém případě je lepší podívat se na systém odspodu a použít modelování pomocí agentů. Při tomto přístupu se zaměříš na jednotlivé části a na vztahy mezi nimi.

M: Takové výrazy jako „dívat se na systém odspodu“ zase zavánějí obecnými frázemi o všem a ničem.

S: Nech mě domluvit. Historicky tento přístup vychází z buněčných automatů, což je přesně definovaný formalismus a žádné řeči o ničem. Na buněčných automatech se dá ukázat spousta zajímavých věcí. Za nejdůležitější považuji princip „jednoduchá pravidla mohou vést ke složitému chování“. Možná to zní jako fráze, ale jde o velmi užitečné pozorování, protože intuitivně očekáváme, že složitě věci kolem nás musí mít i složitě vysvětlení. Buněčné automaty nám názorně ukazují, že tomu tak být nemusí.

M: No dobrá, ale já jsem spíš na králíky než na principy. Mohu pomocí buněčných automatů modelovat rozmístění králíků v prostoru?

S: Na králíky nejsou buněčné automaty úplně vhodné, na to se hodí spíš modelování pomocí agentů. Na rozdíl od buněčných automatů není tento přístup přesným formalismem, ale spíše obecnou metodikou. Neříká ti přesně, jak máš modelovat, ale nabízí ti principy, kterých je užitečné se držet.

M: Můžeš mi to ilustrovat na příkladě?

S: Základní princip říká, že agenti by měli být co nejjednodušší a interakce by měly být lokální. Uvažme tvůj návrh na model rozmístění králíků v prostoru. Agenti budou králíci. Agenti musí mít pravidla, podle kterých se rozhodují. Tato pravidla by měla odrážet chování králíka, ale mají být co nejjednodušší. Třeba můžeme použít pravidlo: když jsi hladový, hledej trávu a požirej ji, když jsi sytý, hledej úkryt. Pravidla dále mají být lokální: agent-králík se nesmí rozhodovat podle celkového rozmístění králíků, trávy a úkrytů, může vzít v potaz jen to, co je v jeho bezprostředním okolí.

M: Dobře, chápu. Ale když jsou to jen metodické principy, jak ten model potom vytvořím?

S: Neboj, existují nástroje pro modelování pomocí agentů, díky nimž můžeš model snadno vyrobit.

M: To zní dobře. Už se těším, jak mi budou ti virtuální králíci pobíhat mezi úkryty. Akorát mám trochu pochybnosti, že to k něčemu bude. Přece jen s těmi jednoduchými pravidly bude ten model pouhou strohou karikaturou skutečnosti.

S: To ale vůbec nevadí. U modelování s agenty nejde o předpovídání chování systémů, a mnohdy nejde ani o přesné vysvětlení principů, na kterých systémy fungují. Jde nám o styl uvažování o systémech – modely často ukazují, že systémy mohou fungovat jinak, než se na první pohled zdá. Například se na nich dá dobře ukázat, jak mohou fungovat decentralizované systémy, ale to ti ukážu někdy jindy.

7.1 Buněčné automaty

Než představíme buněčné automaty formálně, uveďme pro ilustraci jednoduchý příklad. Zůstáváme u populační dynamiky a opět studujeme dynamiku dvou druhů. Tentokrát však uvažujeme nepřímou konkurenci dvou druhů rostlin a studujeme nejen velikost populací, ale také jejich rozšíření v prostoru. V modelu uvažujeme území rozdělené na čtvercovou síť. Pro jednoduchost předpokládáme, že na každém políčku může růst pouze jeden druh rostlin. Dynamika modelu je jednoduchá: postupujeme po kolech, pro každé políčko se vždy podíváme, jaké má bezprostřední sousedy, a na políčku v dalším kole poroste ta rostlina, která je v bezprostředním okolí více zastoupena. Obr. 7.1 ukazuje vývoj modelu z počátečního stavu, ve kterém je několik náhodně umístěných semínek, až do stabilního stavu.

Tento model je samozřejmě velmi abstraktní a nepříliš užitečný. Nicméně poslouží nám dobře pro ilustraci základních charakteristik buněčných automatů:

Diskrétní prostor Buněčný automat je tvořen pravidelnou mřížkou diskretních jednotek – buněk.

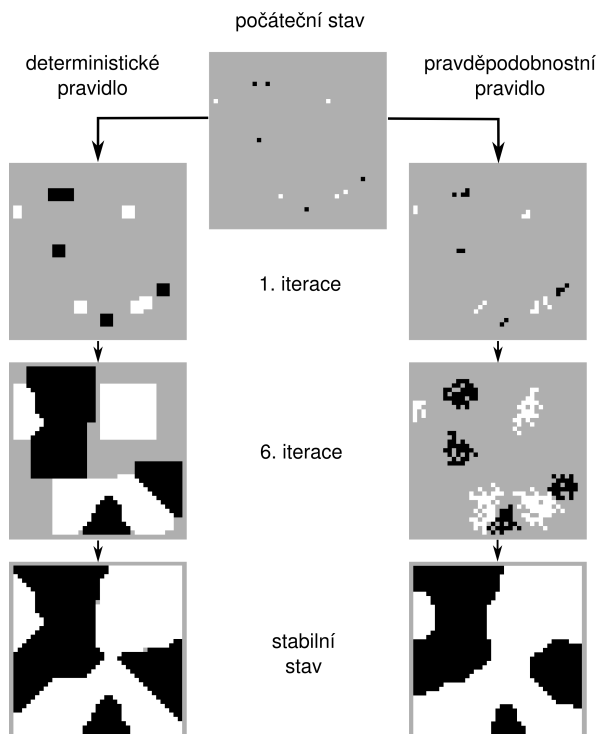
Lokální interakce Buňky mají definováno své okolí, a interakce mezi buňkami probíhá pouze v rámci tohoto okolí, tj. buňka může přímo ovlivňovat pouze buňky ve svém bezprostředním okolí. V modelu nejsou žádné vztahy s dlouhým dosahem, žádné globální entity.

Homogenita Všechny buňky jsou identické a řídí se stejnými pravidly.

Diskrétní stavy Každá buňka může mít jen konečný počet stavů.

Diskrétní dynamika Stav buněk se mění synchronizovaně v diskretních časových krocích.

Z příkladu se šířením rostlin je také vidět, že počítačová simulace je pro studium buněčných automatů téměř nezbytná. I pro tento velmi jednoduchý model by bylo dosti pracné provádět simulaci ručně.




Obr. 7.1: Příklad buněčného automatu: šíření dvou rostlin v prostoru. Šedá barva představuje holé pole, černá a bílá barva představují dva druhy rostlin.

Definice

Na buněčných automatech ilustrujeme také formálnější přístup k modelování. Ve většině kapitol nezacházíme úplně do technických detailů, aby byl text čtivý. V případě buněčných automatů nejsou definice složité, a proto nadefinujeme základní pojmy přesně, aby bylo vidět, že modelování komplexních systémů není jen o obecném povídání a pěkných obrázcích.

Buněčný automat je definován nad množinou buněk M . Téměř vždy se používá jako M nějaká pravidelná mřížka. V této mřížce má každá buňka určeno svoje okolí, přičemž okolí buňky i značíme $N(i)$. Typicky je mřížka dvojrozměrná a čtvercová, buňky jsou udány souřadnicemi $[x, y]$ a jako okolí bereme čtyři bezprostřední sousedy (von Neumannovo okolí) nebo osm sousedů (Moorovo okolí) (viz obr. 7.2). Další často používané mřížky jsou jednorozměrná, dvojrozměrná šestiúhelníková a trojrozměrná. Při teoretických analýzách se buněčné automaty uvažují na nekonečných mřížkách, pro simulaci na počítači však potřebujeme mřížku konečnou. Proto musíme definovat okrajovou podmínku, která určuje, jak zacházet s buňkami na okraji



Obr. 7.2: Příklady okolí buňky.

mřížky. Můžeme například přiřadit okrajovým buňkám fixní hodnotu nebo využívat periodickou okrajovou podmínku (u dvojrozměrné mřížky to znamená, že spojíme horní okraj s dolním a levý okraj s pravým a dostaneme tak torus).

Každá buňka může nabývat jednoho z konečně mnoha lokálních stavů. Formálně to znamená, že máme konečnou množinu stavů Σ velikosti k , přičemž bez újmy na obecnosti můžeme předpokládat, že $\Sigma = \{0, \dots, k-1\}$. Stav i -té buňky v čase t značíme $\sigma_i(t) \in \Sigma$.

Dynamika buněčného automatu je dána přechodovým pravidlem. Pravidlo ϕ určuje následující stav na základě stavů buněk v okolí, tj. $\phi: \Sigma^n \rightarrow \Sigma$, kde n je velikost okolí:

$$\sigma_i(t+1) = \phi(\sigma_j(t), j \in N(i))$$

Tímto máme definovanou syntax (zápis) buněčného automatu a nyní musíme definovat sémantiku (význam). Sémantikou buněčného automatu je stavový prostor, tj. množina stavů a přechody mezi nimi. Stav buněčného automatu je přiřazení lokálních stavů všem buňkám, tj. totální zobrazení $M \rightarrow \Sigma$. Přechody mezi stavy odpovídají provedení jednoho synchronního kroku podle přechodového pravidla (stav všech buněk se mění současně). Všimněme si, že sémantika je deterministická – každý stav má právě jednoho následníka. Pokud uvažujeme buněčný automat nad konečnou mřížkou, pak je zjevně stavový prostor konečný (má velikost $k^{|M|}$), tj. každý výpočet automatu se někdy zacyklí.

Ilustrujme definice na výše uvedeném příkladě šíření dvou druhů rostlin (obr. 7.1):

- Mřížka M : pravidelná čtvercová mřížka velikosti 32×32 , tj. $M = \{1, \dots, 32\} \times \{1, \dots, 32\}$.
- Okolí: Moorovo okolí (8 buněk).
- Množina lokálních stavů: $\Sigma = \{0, 1, 2\}$ (0 odpovídá neobsazenému poli, 1 a 2 odpovídají jednotlivým druhům rostlin).
- Okrajová podmínka: fixní (okrajové buňky mají fixní stav 0).
- Přechodové pravidlo: Nechť $a_{i,j}(t)$ (resp. $b_{i,j}(t)$) je počet sousedů buňky $[i, j]$, kteří jsou v čase t ve stavu 1 (resp. ve stavu 2). Pokud
 - $a_{i,j}(t) > b_{i,j}(t)$, pak $\sigma_{i,j}(t+1) = 1$,
 - $b_{i,j}(t) > a_{i,j}(t)$, pak $\sigma_{i,j}(t+1) = 2$,
 - jinak $\sigma_{i,j}(t+1) = \sigma_{i,j}(t)$.
- Stav buněčného automatu je dán funkcí σ .

Rozšíření buněčných automatů

Základní formalismus, který jsme uvedli výše, lze mnoha způsoby upravovat a rozšiřovat. Některé variace jsou zaměřeny na teoretická studia (např. totální, reverzibilní či aditivní automaty), jiné jsou zaměřeny na praktické aplikace (např. spojitě, nehomogenní, strukturně-dynamické automaty). Z hlediska praktické aplikace při modelování komplexních systémů je důležité především rozšíření o pravděpodobnostní pravidla.

Pravděpodobnostní buněčné automaty fungují stejně jako klasické buněčné automaty kromě jediné výjimky – přechodová pravidla nejsou deterministická, ale pravděpodobnostní. Ilustrujme tento rozdíl na příkladě šíření rostlin:

- Deterministická verze pravidla:
Pokud sousedů typu 1 je více než sousedů typu 2, pak v příštím kole bude toto pole typu 1.
- Pravděpodobnostní verze pravidla:
Pokud sousedů typu 1 je více než sousedů typu 2, pak v příštím kole bude toto pole s pravděpodobností 10 % typu 1 a s pravděpodobností 90 % zůstane ve stejném stavu jako nyní.

Obr. 7.1 ukazuje kromě chování s deterministickým pravidlem také chování s pravidlem pravděpodobnostním – u tohoto jednoduchého modelu není rozdíl mezi deterministickým a pravděpodobnostním modelem zásadní, ale už zde je vidět, že šíření rostlin je v pravděpodobnostním případě věrohodnější. V dále uváděných modelech budeme používat téměř výlučně pravděpodobnostní buněčné automaty.


Souvislosti: Stručný přehled základních faktů o buněčných automatech s důrazem nejen na modelování, ale i na teoretické studie a další aplikace podává Flake (2000). Detailní technický přehled nabízí Ilachinski (2001) a dále Wolfram (2002), který diskutuje i souvislosti a pouští se do obecných úvah o vědě.

7.2 Příklady buněčných automatů

Pro ilustraci zde uvedeme velmi jednoduché modely, jejichž účelem je demonstrovat základní podstatu určitého přírodního mechanismu. Kromě modelování a simulace komplexních systémů se buněčné automaty používají také v dalších oblastech, např. jako výpočetní mechanismus (hardwarová implementace strojů na základě principů buněčných automatů) a jako fundamentální modely ve fyzice (na místo standardního spojitého modelu).

Vznik vzorů

Jak vznikají vzory na mušlích? Jak to, že mají sněhové vločky takové složité tvary? Kde vzala zebra svoje pruhy a leopard skvrny? Při hledání odpovědí na tento typ



Obr. 7.3: Model formování vzorů na kůži: výsledný stav modelu pro tři různá nastavení parametrů.

otázek můžeme s výhodou využít buněčné automaty. Pro ilustraci představíme jednoduchý buněčný automat, který ilustruje základní mechanismus vytváření vzorů na kůži u takových tvorů, jako je zebra, žirafa, leopard či tygr.


Buňky jsou uspořádány v pravidelné mřížce. Každá buňka je buď aktivní (černá), nebo neaktivní (bílá). Aktivní buňky vysílají dva signály: aktivační a inhibiční. Aktivační signál podporuje aktivaci okolních buněk a je silnější než inhibiční, ale má jen krátký dosah (řekněme v poloměru tří buněk). Inhibiční signál podporuje deaktivaci okolních buněk. Je sice slabší než aktivační, ale má delší dosah (řekněme v poloměru šesti buněk). Celkově tedy můžeme říct, že aktivní buňka podporuje aktivaci buněk v blízké vzdálenosti a podporuje deaktivaci buněk ve střední vzdálenosti.

Obr. 7.3 ukazuje příklady výstupů tohoto modelu. Ve všech případech začínáme z náhodného stavu, necháme systém vyvíjet podle uvedených pravidel a čekáme, až se stav ustálí. Uvedené tři případy se liší pouze nastavením parametrů modelu (velikost okolí, relativní síla aktivačního a inhibičního signálu). Jak je vidět, uvedený jednoduchý mechanismus může vést ke vzniku rozmanitého spektra vzorů.


Voda v krajině

Obr. 7.4 ukazuje snímky modelu, který ilustruje tvarování krajiny vlivem eroze způsobené vodou. Každé pole (buňka) má přiřazenu výšku a množství vody, kterou drží – tyto dvě informace dohromady určují stav buňky. V počátečním stavu máme mírně vlnitou krajinu, tj. výška mírně kolísá (náhodně vygenerováno). V průběhu simulace na pole náhodně přibývá voda (déšť). Pro simulaci toku vody se používá jednoduché pravidlo: voda se přesouvá na vedlejší pole, které je níže, množství přesunuté vody odpovídá rozdílu v množství vody mezi vybranými poli. Kromě přesunu vody dochází také k erozi – z pole, ze kterého teče voda, se odplaví i hlína, tj. dojde k snížení výšky. Jak je vidět z obrázku, i tato jednoduchá pravidla stačí k vytvoření zajímavého „říčního“ systému.

Model můžeme dále rozšířit a ilustrovat na něm vliv stromů na koloběh vody v krajině. Rozlišíme pole na holá a zalesněná. Pravidla upravíme tak, že ze zales-



Obr. 7.4: Model eroze: tři snímky vývoje modelu.



Obr. 7.5: Model krystalizace: šedé útvary znázorňují „teplé“ atomy, černé útvary pak atomy „studené“.

něných polí se voda přesouvá pomaleji, což odpovídá tomu, že stromy zadrží více vody než holé pole. Pomocí rozšířeného modelu můžeme například ukázat, jak se liší odezva holé a zalesněné krajiny na přívalové deště.

Krystalizace

Pomocí buněčných automatů lze ilustrovat také mnoho chemických a fyzikálních jevů. Zde zmíníme model krystalizace (obr. 7.5). Buňky představují atomy kovu. Na počátku simulace je kov horký, atomy jsou náhodně natočeny. Během simulace se kov postupně od kraje plochy ochlazuje. Jakmile se atom ochladí pod určitou mez, zaujme pevnou pozici, kterou již později nemění. Tato pozice atomu závisí na orientaci okolních atomů, především těch chladných. Výsledkem simulace je vznik „zrn“ stejně orientovaných atomů.

Souvislosti: Modely uvedené na obr. 7.3, 7.4, 7.5 pocházejí z knihovny nástroje NetLogo (Wilensky, 1998). V této knihovně lze nalézt i další příklady použití buněčných automatů, z nichž některé jsou popsány také v kapitolách 12.1 (sebe-reprodukce, hra Život) a 12.4 (model Svět sedmikrásek).

7.3 Modelování založené na agentech

Nejprve ujasněme terminologii. Přístup k modelování, kterým se zabýváme v následující pasáži, bývá označován různými (anglickými) termíny: agent-based modeling (ABM), individual-based modeling (IBM), agent-based systems (ABS), agent-based modeling and simulation (ABMS). Protože české překlady nejsou příliš elegantní a žádný z nich není příliš rozšířený, budeme v této knize používat zkratku ABM, jelikož je ze zkratk anglických termínů nejčastěji používaná a žádný standardně užívaný český termín ani zkratka v současné době neexistují.

Základními teoretickými východisky ABM jsou buněčné automaty (decentralizace, lokální interakce) a umělá inteligence (učení, vývoj). Nutno podotknout, že v oblasti umělé inteligence se výraz „agent“ používá v daleko širším významu, než jak jej používáme zde, viz např. Wooldridge (2009). Má smysl studovat i „jednoho složitého agenta“, kdežto my zde budeme mluvit téměř výhradně o „mnoha jednoduchých agentech“. Naše použití výrazu „agent“ je tedy vázáno na přístup ABM.

Základní principy

ABM není žádný přesně definovaný formalismus ani fixní metodika. Je to spíše soubor základních principů k návrhu modelu:

- Modely jsou založeny na autonomních agentech. Agenti se rozhodují každý sám za sebe, nedostávají žádné příkazy shora (od centrální autority).
- Důležitou součástí modelů je prostředí, ve kterém se agenti pohybují a jež se může měnit – buď interakcí s agenty, nebo samovolně.
- Interakce jsou pouze lokální – to se týká jak interakcí mezi agenty, tak interakcí mezi agenty a prostředím.
- Agenti jsou jednoduší, důraz je kladen na interakce mezi agenty, nikoliv na agenty samé. Modely tedy typicky obsahují velké množství jednoduchých agentů, nikoliv malé množství sofistikovaných agentů.

Agenti

Základem ABM jsou pochopitelně agenti, což jsou jasně určené, samostatné, diskrétní jednotky. Při návrhu agentů je obzvláště důležité myslet na účel modelu – je snadné podlehnout tendenci k naivnímu realismu a udělat pravidla agentů příliš komplikovaná. Pravidla, kterými se řídí chování agentů, by měla být co nejjednodušší, dbáme přísně na použití pouze lokálních interakcí. Použití jakýchkoli globálních informací musí být dobře odůvodněno (vzhledem k účelu modelu).

Důležitou součástí ABM je heterogenita a náhodnost. Rozdílnost agentů může obohatit ABM modely a jde do nich jednoduše začlenit. Heterogenitu můžeme začlenit přímočaře použitím různých typů agentů (např. lovec a kořist) nebo pomocí paměti agentů (každý agent má svou vlastní paměť a tím se agenti rozlišují). Heterogenity dosahujeme také pomocí náhodnosti, například tak, že si každý agent vybírá svoji akci s přihlédnutím k náhodě nebo že určitou vlastnost agentů (například délku života) rozdělíme v populaci náhodně. U většiny modelů je také vhodné spouštět jednotlivé agenty v náhodném pořadí. Pokud spouštíme agenty pravidelně (například po řádcích pravidelné mřížky), může dojít k nežádoucím důsledkům.

ABM modely mohou vcelku přímočaře začlenit vývoj agentů. Agenti si mohou pamatovat zkušenosti a podle nich měnit své chování, učit se, může docházet k vývoji, evoluci. V této kapitole se těmito rysy nezabýváme, na adaptaci se podíváme blíže v následující kapitole.

Prostředí

Musíme také specifikovat prostředí, ve kterém se agenti pohybují. Nejčastěji používané typy prostředí jsou následující:

- Euklidovská geometrie (1D, 2D, 3D). Poloha agenta je dána souřadnicemi, při určování lokálního okolí a pohybu pracujeme s euklidovskou vzdáleností.
- Pravidelná mřížka (1D, 2D, šestiúhelníková) – podobně jako u buněčných automatů, používáme například von Neumannovo okolí nebo počítáme vzdálenosti pomocí počtu buněk, přes které je nutno projít.
- Graf. V některých případech není důležité fyzické rozmístění bodů v prostoru, ale určitý vztah mezi jednotlivými body. Příkladem může být počítačová síť. O grafech a jejich použití pro ABM modely se zmíníme podrobněji v kapitole 9.
- Jeden bod. Všichni agenti jsou na jedné hromadě, tj. prostředí se redukuje na jeden bod, agenti se nijak nepohybují, každý může interagovat s kýmkoliv.

Pro výpočetní model potřebujeme uzavřené, konečné prostředí. Když používáme euklidovskou geometrii nebo mřížku, musíme velikost prostředí omezit. V těchto případech se většinou používá „toroidní svět“ („pneumatika“), tj. z jednoho okraje plochy se dostáváme na druhý okraj plochy. Alternativně můžeme použít „mantinely“, tj. na okraji prostředí je hradba, kterou agenti nemohou překonat.

Prostředí nemusí být jen pasivní plochou, po které se agenti pohybují. Může mít svoje parametry a chování, prostřednictvím kterého dochází k jednostranné nebo oboustranné interakci s agenty, případně s okolními body prostředí.

Souvislosti: Nástroje, které lze použít pro realizaci modelů s agenty, jsou popsány v příloze C. K modelování pomocí agentů zatím neexistují ucelené souhrnné materiály, existuje však mnoho zdrojů, které diskutují ABM z určitého pohledu. Resnick (1997) se zaměřuje na využití ABM pro výuku decentralizovaného myšlení; Flake (2000) rozebírá nejznámější příklady; Gilbert a Troitzsch (2005), Miller a Page (2007) a Gilbert (2008) se zaměřují na sociální vědy; Grimm a Railsback (2005) na ekologii; Camazine et al. (2003) na biologii a samo-organizaci. Každá z těchto knih popisuje stručně i metodiku modelování a konkrétní příklady z dané oblasti.

7.4 Příklady modelů založených na agentech

Spíše než abychom prováděli složité metodické úvahy, ilustrujeme základní koncepty s využitím jednoduchých příkladů. V dalších kapitolách pak zmíníme složitější ABM modely včetně kombinace základních principů s dalšími technikami, jako je učení a sítě.

Lovec-kořist

Příklad lovec-kořist využijeme zejména pro srovnání se systémovou dynamikou. Podobně jako při systémovém modelování modelujeme lišky (lovce) a králíky (kořist) za zjednodušeného předpokladu, že lišky se živí pouze králíky. V tomto případě však nemodelujeme celkové počty lišek a králíků, ale jednotlivé tvory a jejich chování:


- Prostředí: 2D euklidovský prostor (případně mřížka).
- Agenti: jednotlivá zvířata (máme dva druhy agentů: lišky a králíky).
- Pravidla agentů:
 - Náhodný pohyb.
 - Interakce (požírání): pokud se liška vyskytne blízko králíka, tak králíka sežere.
 - Množení a smrt. Králíci se množí při dosažení produktivního věku, umírají buď stářím, nebo když je sežere liška. Lišky se množí a umírají podle svého stáří a energetické bilance (kolik králíků sežraly).

Celkové chování modelu dostáváme podobně jako u systémové dynamiky, tj. oscilace, kdy křivka početnosti lovce sleduje se zpožděním křivku početnosti kořisti.

Souvislosti: Chování tohoto modelu (resp. jeho variace králík-tráva) je detailně rozebráno v kapitole 10.

Segregace

Pravděpodobně nejznámějším ABM modelem je model segregace, který Thomas Schelling studoval již v 70. letech, tenkrát ještě bez počítačů, pouze pomocí mincí a manuální simulace. Model ilustruje, jak může dojít k výrazné rasové segregaci i v případě relativně tolerantních obyvatel.



Obr. 7.6: Model segregace, tolerance 30 %.

- Prostředí: pravidelná mřížka $n \times n$ polí.
- Agenti: dva druhy obyvatel (bílé, černí), každý obývá jedno políčko na mřížce, obsazeno je zhruba 80 % polí.
- Pravidla agentů:
 - Agent si spočítá podíl p agentů stejného druhu mezi svými bezprostředními sousedy.
 - Agenti mají toleranci t . Pokud $p \geq t$, agent nic nedělá. Pokud $p < t$, agent se přestěhuje na náhodné volné pole.

Každý obyvatel tedy vyžaduje, aby alespoň část jeho bezprostředních sousedů byla stejná jako on, tato hranice je určena mírou tolerance. Pokud podmínka není splněna, obyvatel je nespokojený a přestěhuje se.

Chování modelu je ilustrováno na obr. 7.6. I při značné toleranci, kdy obyvatelům stačí 30 % stejných sousedů, dochází k vytváření jednodruhových shluků (ghet) a k výrazné segregaci – průměrný počet stejných sousedů je 70 %. Jde o typický příklad emergentního chování: celková vysoká míra segregace a vytváření ghet nemá přímý předobraz v pravidlech jednoduchých agentů. Model také ukazuje, jak může být zavádějící usuzovat z chování celku na motivy (pravidla chování) jednotlivců.

Souvislosti: Původním autorem modelu segregace je Schelling (1969). Zde použitá verze pochází z knihovny nástroje NetLogo (Wilensky, 1998), kde lze nalézt mnoho dalších příkladů modelování s agenty. Některé příklady jsou také popsány v třetí části knihy: kapitoly 11 a 12 popisují několik jednoduchých modelů, kapitoly 13 a 14 pak rozsáhlejší studie.

7.5 Shrnutí

- Tato kapitola se zabývá modelováním odspodu, důraz je kladen na chování dílčích částí systému a na lokální interakce.
- Základní prvky buněčného automatu jsou mřížka, lokální okolí, konečně mnoho lokálních stavů, přechodové pravidlo a diskrétní synchronní změna stavů.

- Jednoduchá pravidla mohou vést ke složitému chování.
- Buněčné automaty můžeme využít pro ilustraci základních mechanismů přírodních jevů, jako jsou například vznik vzorů, eroze nebo chemické reakce.
- Modelování založené na agentech (ABM) je založeno na velkém počtu autonomních, jednoduchých agentů, kteří využívají pouze lokální interakce.
- ABM není fixní metodika ani formalismus, ale spíše přístup k modelování a soubor užitečných principů.
- Pojem „agent“ se v oblasti umělé inteligence používá v širším významu, než jak jej používáme zde.

8 Modelování myšlení a vývoje

M: Hledal jsem další podklady o králících a zjistil jsem, že v pohádkách a mýtech často vystupuje králík jako mazaný tvor, který ostatní přechytračí. Moji virtuální králíci se zatím akorát tupě množí nebo skáčou po louce podle fixních pravidel. Lze do modelů zapojit i inteligenci či rozhodování?

S: Základní způsob, jak modelovat rozhodování, je vyjít z předpokladu racionality a využít teorii her. V modelu teorie her má každý hráč – řekněme králík, liška a farmář – několik strategií. Králík může jít na zahrádku hrabat mrkev nebo na palouk požírat trávu, liška může jít číhat na králíka nebo zkusit uloupit slepici, farmář hlídá zahrádku nebo slepice. Pro každou možnost pak vyjádříme, jaký z ní mají jednotliví hráči zisk: třeba když farmář hlídá slepice, králík hrabe mrkev a liška číhá na slepice, králík z toho má velký zisk. Na základě těchto pravidel pak zkoumáme, co jsou nejlepší strategie pro jednotlivé hráče.

M: Dobrá, ale to se asi hodí leda na modelování lidského rozhodování, a i tam stěží. Dost pochybuju, že normální lidi strategicky plánují. U králíků asi nemohu předpokládat příliš racionální chování. Lepší by bylo, kdyby se ti mí virtuální králíci učili ze zkušeností – když zjistí, že na palouku je chutná tráva a nejsou tam žádné lišky, tak se tam příště vrátí.

S: Však to jde namodelovat taky. K modelování učení můžeš použít třeba umělou neuronovou síť, což je formalismus, který simuluje fungování mozku. Pro tvůj příklad však bude lepší produkční systém, což je metoda založená na podmíněných pravidlech, kterým se dynamicky mění priority.

M: Aha, tak to mi budeš muset vysvětlit trochu podrobněji. Ale než půjdeme do detailů, ještě mě napadla jedna věc. Dočetl jsem se, že dlouhé uši králíků jsou nejspíše „adaptace pro detekování predátorů“. Šlo by udělat jednoduchý model evoluce, který by ilustroval, jak se přírodním výběrem vyvíjejí dlouhé uši u králíků?

S: Určitě. Nejtypičtější přístup pro modelování evoluce jsou takzvané genetické algoritmy. Vlastnosti králíků zakóduješ jako binární řetězec, vyjádříš zdatnost jednotlivých králíků a pak provádíš výběr nejzdatnějších, necháváš je křížit a mutovat a sleduješ, co se z toho vyvine.

8.1 Teorie her a racionální uvažování

Naši exkurzi do modelování myšlení a vývoje začneme s teorií her, což je přístup využívaný především pro modelování racionálního uvažování při strategických rozhodnutích. Modely se v této oblasti nazývají hry a jsou vhodné pro zachycení situací, které mají zhruba následující prvky:

- Každý hráč (agent) má několik možností, mezi kterými se musí rozhodnout.
- Hráči při svém rozhodování berou v potaz potenciální akce ostatních.
- Všichni hráči se chovají racionálně – snaží se najít optimální rozhodnutí, přičemž k tomu využívají všechny dostupné informace.

Použití modelů z oblasti teorie her je do značné míry omezeno právě předpokladem racionality. Ostatně třeba i učebnice standardní teorie her (Osborne, Rubinstein, 2004) v úvodě zmiňuje: „Předpoklady, na kterých leží teorie racionálního rozhodování, zde nerozebíráme. Musíme však zmínit, že tyto předpoklady jsou pod stálým útokem experimentálních psychologů, kteří trvale ukazují na výrazné limity jejich použitelnosti.“

To však zdaleka neznamená, že by teorie her byla pro modelování komplexních systémů irelevantní. V třetí části knihy uvádíme několik příkladů, ve kterých se teorie her kombinuje s dalšími modelovacími přístupy a umožňuje nám tak modelovat nejen racionální rozhodování. Zde však zatím zůstaneme pouze u základních pojmů klasické teorie her a ilustrujeme je na jednoduchých příkladech.

Hry

Pro jednoduchost zmíníme pouze nejjednodušší typ her, které se označují jako strategické hry nebo též hry v normální formě. Strategická hra pro n hráčů je zadána množinou akcí pro každého hráče a funkcí zisku, jež pro každou možnou kombinaci zvolených akcí udává, jaký je zisk hráče i .

Základní model strategických her předpokládá, že hra je jednokolová a že všichni hráči volí svoji akci současně a nezávisle. Za těchto předpokladů můžeme hru zapsat prostřednictvím n -rozměrné tabulky, ve které do každého políčka zapíšeme n hodnot udávajících zisk jednotlivých hráčů. Tento způsob zápisu je praktický obzvláště pro $n = 2$, protože dvourozměrné tabulky se dobře zapisují na papír.

Obr. 8.1 ukazuje zápis hry pomocí tabulky pro dva známé příklady. Kámen, nůžky, papír je známá hra, ve které hráč volí jeden ze tří symbolů, zisk 1, 0, -1 odpovídá výhře, remíze a prohře podle obecně známých pravidel. Hra Souboj pohlaví modeluje situaci, kdy se partneři zapomněli domluvit, kam půjdou večer za zábavou, a tak se musí každý z nich samostatně rozhodnout, zda půjde do divadla, či na fotbal (jde o tradiční příklad pocházející z dob, kdy nebyly mobilní telefony). Žena upřednostňuje divadlo, muž fotbal, pro oba je však důležitější, aby strávili večer společně.

Velmi důležitý pojem, který zavádí teorie her, je pojem hry s nulovým a nenulovým součtem. Hra s nulovým součtem je taková, kdy součet zisků jednotlivých hráčů je nulový, tj. aby jeden hráč vyhrál, druhý musí prohrát. Hra Kámen, nůžky, papír je typickým příkladem hry s nulovým součtem, další příklady jsou klasické deskové

Kámen, nůžky, papír				Souboj pohlaví		
1. hráč \ 2. hráč	kámen	nůžky	papír	žena \ muž	divadlo	fotbal
kámen	0; 0	1; -1	-1; 1	divadlo	3; 2	1; 1
nůžky	-1; 1	0; 0	1; -1	fotbal	0; 0	2; 3
papír	1; -1	-1; 1	0; 0			

Obr. 8.1: Příklady her ve strategické formě.

hry nebo většina sportů a soutěží. Hra s nenulovým součtem je taková, kdy součet zisků jednotlivých hráčů není nulový, tj. oba hráči mohou současně vyhrát i prohrát. Hra Souboj pohlaví je příkladem hry s nenulovým součtem. Do této kategorie patří většina reálných životních situací.

Strategie

Strategická hra je model popisující rozhodovací situaci. Sama o sobě však hra situaci pouze popisuje, ale neříká, jak se hráči zachovají. Od toho máme strategie, které z množiny dostupných akcí vybírají tahy hráčů. Rozlišujeme dva základní typy strategií:

- Čistá strategie vybírá fixně jednu z možných akcí (např. „hraj kámen“).
- Mixovaná strategie udává pravděpodobnostní distribuci přes možné akce (např. „hraj v 50 % kámen, ve 40 % papír a v 10 % nůžky“).

Jaká je nejlepší strategie pro každého hráče? Strategie jednotlivých hráčů nelze studovat izolovaně – co je výhodný tah pro hráče A, závisí na tom, co udělá hráč B. Proto se zavádí a studuje pojem ekvilibria, což je taková kombinace strategií, při které si ani jeden z hráčů nemůže polepšit změnou svého tahu.

Ilustrujme koncept ekvilibria na našich příkladech. Například ve hře Souboj pohlaví situace, kdy žena volí divadlo a muž fotbal, není ekvilibriem, protože například žena si může polepšit tím, že půjde na fotbal. Naproti tomu situace, kdy oba dva jdou do divadla, je ekvilibriem, protože ani jeden si změnou své volby nemůže polepšit (druhým ekvilibriem této hry je situace, kdy jdou oba dva na fotbal).

Existuje ekvilibrium ve hře Kámen, nůžky, papír? V rámci čistých strategií nikoliv. Když nastane třeba situace kámen versus nůžky, tak si druhý hráč může polepšit tím, že zvolí papír. Podobná analýza platí pro každou další situaci. Pokud hráči používají smíšené strategie, ekvilibrium existuje – tvoří jej strategie „hraj kámen, nůžky, papír každé s pravděpodobností 1:3“.

Klasická matematická teorie her se zabývá především analýzou různých definic ekvilibria (výše uvedená slovní definice popisuje koncept Nashova ekvilibria), popisem ekvilibria pro různé typy her, studiem existence ekvilibria a podobně. Méně už se ovšem zabývá například tím, jak se situace dostane do ekvilibria a jak se vybere mezi více ekvilibrii (tak půjdou tedy do divadla, nebo na fotbal?). Ke studiu těchto

otázek se hodí zapojit počítačovou simulaci. Jak se to dá prakticky provést, ukážeme v dalších kapitolách.

Souvislosti: Teorie her je rozsáhlá disciplína, ke které existuje celá řada učebnic, zmíníme například (Osborne, Rubinstein, 2004). Modely založené na teorii her jsou rozebrány především v kapitole 14 (hra Dilema vězně a další modely spolupráce) a v kapitole 12.2 (model Jestřáb a holubice a pojem evolučně stabilní strategie).

8.2 Modelování induktivního myšlení

Jak jsme již opakovaně zmínili, lidé většinou neuvažují striktně racionálně. Myšlení je většinou induktivní – vycházíme z předchozích zkušeností, které zobecňujeme a zkoušíme používat v nových situacích (viz příklad s používáním nového přístroje na str. 35). Jak můžeme modelovat takový styl myšlení?

Existují dva základní přístupy: symbolický a konekcionistický. Symbolické modelování přistupuje k myšlení na vysoké, abstraktní úrovni. Myšlení modelujeme pomocí pravidel, která manipulují se symboly. Například pokud modelujeme, jak se děti učí počítat, bude takový model pracovat se symboly, jako jsou „+“ a „3“ a s pravidly typu „pokud chci vypočítat $X + 0$, výsledek je X “.

Jeden z problémů symbolického modelování je skryt v otázce „Kde se vezmou symboly?“ Zůstaňme u příkladu se sčítáním. Dítě, které se dívá na početní příklad zapsaný na papíře, dostává do mozku skrze oko pouze informace o černých a bílých skvrnách – tuto informaci musí nejprve interpretovat a nějakým způsobem „vyrobit“ symboly „+“ a „3“.

Na takovéto problémy se zaměřuje konekcionistické modelování, které pracuje na nižší, méně abstraktní úrovni než symbolické modely. Typicky jde o modely, jež napodobují základní principy fungování mozku, tj. jde o sítě vzájemně propojených virtuálních neuronů.

Když začínal výzkum v oblasti výpočetního modelování myšlení, což bylo zhruba v 60. a 70. letech 20. století, panovala mezi výzkumníky řevnivost o to, který přístup je ten správný. Dnes se vesměs uznává, že oba přístupy mají své aplikační oblasti, a často se také používají hybridní modely, které kombinují jak symbolické, tak konekcionistické principy. Obě oblasti jsou velmi rozsáhlé, takže zde ilustrujeme pouze hlavní principy základních typů modelů.

Než se podíváme na konkrétní příklady, uvedeme ještě pár souvislostí. Modelování induktivního myšlení spadá pod obecnější oblast kognitivního modelování a tato oblast souvisí s příbuzným oborem umělé inteligence. Cílem kognitivního modelování je zachytit, jak funguje lidská mysl. Budujeme modely, které jsou pokud možno jednoduché a věrné realitě, zaměřujeme se na principy. „Výkon“ modelů (jak dobře řeší konkrétní problém) zde není zdaleka jediným kritériem posuzování modelů (další kritéria jsou například, zda a jak model zapadá do nějaké celkové teorie fungování

mysli). V umělé inteligenci je primárním cílem reprodukce inteligentního chování. Biologické principy a fungování lidské mysli jsou pouze inspirací. Důraz je zde kladen především na „výkon“. Tato charakterizace je pochopitelně zjednodušující, ve skutečnosti jde o prolínající se oblasti.

Souvislosti: Pěkný přehled této oblasti dává encyklopedie kognitivní vědy (Wilson, Keil, 1999), konkrétně pro kognitivní modelování pak dobrý úvod podává Sun (2008). Úvod do klasické umělé inteligence poskytují Russell a Norvig (2009). Z česky psaných knih stojí za pozornost série knih Umělá inteligence (Mařík et al., 1993–2003), která zasahuje do obou zmíněných oblastí.

Symbolické modelování: produkční systémy

Typickým symbolickým modelem jsou produkční systémy. V produkčním systému mají všechna pravidla tvar „pokud nastane podmínka P, pak proved akci A“ a standardně se zapisují pomocí anglických výrazů IF-THEN. Můžeme si to představit třeba následovně:

```
IF chci čaj THEN uvařit čaj
IF chci čaj THEN dát si čaj v hospodě
IF uvařit čaj a nemám horkou vodu THEN dát vodu do konvice
IF dát si čaj v hospodě THEN zajít do hospody a objednat čaj
```

Tento příklad je zapsaný vágně, a rozhodně tedy nejde o výpočetní model, můžeme však na něm dobře ilustrovat základní rysy produkčních systémů:

- Pravidla jsou „paralelní“, nemáme žádný sekvenční tok nebo zanořování jako v programovacích jazycích.
- Pravidla mohou být kolizní, tj. v určité situaci může být aplikovatelných více pravidel (např. situace „chci čaj“). Jak pak vybereme pravidlo, které se má provést? Pravidla mohou mít přiřazenu prioritu, která udává šanci, s jakou bude pravidlo vybráno k použití. Výběr pak probíhá náhodnostně s přihlédnutím k těmto prioritám.
- Akce pravidel mohou přímo vyvolávat vnější akci (např. „dát vodu do konvice“) nebo mohou sloužit ke komunikaci v rámci systému tím, že vyvolávají další pravidla (např. interní cíl „uvařit čaj“).

Učení v produkčním systému probíhá dvěma základními způsoby: úpravou způsobu řešení kolize (např. priorit jednotlivých pravidel) a vývojem nových pravidel. Úprava priorit pravidel zvyšuje prioritu úspěšným pravidlům a snižuje prioritu pravidlům neúspěšným. Vývoj nových pravidel funguje například pomocí spojení dvou pravidel, která se často používají hned za sebou (např. první a třetí pravidlo z našeho příkladu), nebo mutací existujícího pravidla (např. „hospodu“ nahradíme za „kavárnu“).

Souvislosti: Konkrétní příklad realizace těchto konceptů jsou třeba Hollandovy klasifikační systémy, viz detailní popis od autora (Holland, 1995), případně stručný čtivý přehled od Flaka (2000). Příkladem propracované „kognitivní architektury“ založené na produkčních systémech je systém ACT-R (Anderson et al., 2004).

Na jednoduchém modelu „El Faron bar“ nyní ukážeme rozdíl mezi racionální strategií a induktivním myšlením modelovaným pomocí produkčního systému. Název příkladu je odvozen od reálného baru ve městě Santa Fe, kde se nachází známý institut zabývající se komplexními systémy. V baru hrají ve čtvrtek večer irskou hudbu. Pro účel modelového příkladu předpokládáme, že v okolí baru žije 100 lidí. Každý z nich by rád zašel ve čtvrtek večer do baru, ale když je tam moc narváno, za nic to nestojí. Přesněji řečeno, pokud je v baru méně než 60 lidí, je lepší být v baru než doma, jinak je lepší být v doma.

Všichni se rozhodují současně, neprobíhá žádná domluva. Pomocí teorie her bychom situaci mohli vyjádřit jako hru pro 100 hráčů, ve které má každý dvě volby (jít do baru, zůstat doma). Můžeme odvodit, že optimální strategie je mixovaná pravděpodobnostní strategie „běž do baru s 60% pravděpodobností“. To je sice pěkné, ale málo lidí se rozhoduje tak, že si deduktivně odvodí správnou pravděpodobnost a pak si hodí kostkou. V realitě se lidé rozhodují induktivně na základě minulých zkušeností.

Pomocí produkčního systému můžeme induktivní rozhodování namodelovat. Každý agent má několik hypotéz pro předpovídání počtu návštěvníků na základě návštěvnosti v minulých týdnech. Předpokládejme například, že dosavadní sekvence počtu návštěvníků v baru byla: 67, 84, 34, 45, 76, 40, 56, 22, 35. Příklady hypotéz, které mohou agenti používat (v závorce je uvedena předpověď pro zmíněnou sekvenci):

- stejně jako minulý týden (35),
- zaokrouhlený průměr za minulé čtyři týdny (49),
- stejně jako před dvěma týdny (22),
- zrcadlový obraz okolo 50 z minulého týdne (65),
- konstantní odhad 42 (42).

Každý agent si udržuje v paměti množinu takových hypotéz. Pro každou hypotézu si agent pamatuje její úspěšnost v historii. V každém okamžiku se rozhoduje podle průměru několika nejúspěšnějších hypotéz. V základní variantě modelu jsou hypotézy vygenerovány autorem modelu a každý agent má náhodně přiřazeno několik z nich.

Výsledky simulace tohoto modelu ukazují, že počet návštěvníků osciluje okolo hodnoty 60, což je výsledek, který bychom očekávali i u reálné situace. Deduktivní řešení s pravděpodobnostní strategií sice vede k mírně lepšímu výsledku (menší oscilace), nicméně je vidět, že i induktivně uvažující agenti řeší problém dobře. Tuto základní modelovou situaci je navíc možno dále rozšiřovat, například o tvorbu nových hypotéz či o komunikaci mezi agenty.

Souvislosti: Problém El Faron baru zavedl Arthur (1994a). Na podobném principu jako model El Faron baru funguje i model umělého trhu s učícími se agenty, který je uveden v kapitole 13.2.

Konekcionistické modelování: umělé neuronové sítě

Kdyby byl mozek tak jednoduchý, že bychom mu mohli rozumět, byli bychom tak jednoduší, že bychom nemohli. (L. Wattson)


Typickým příkladem konekcionistického modelu jsou umělé neuronové sítě, což je model založený na zjednodušené imitaci fungování mozku. Základem umělé neuronové sítě jsou umělé neurony spojené váženými vazbami. Znalosti jsou v síti uloženy jako váhy spojení mezi neurony a učení probíhá změnou těchto vah. Znalosti jsou tedy v síti, podobně jako v mozku, uloženy distribuovaně a nemůžeme je jednoduše lokalizovat a interpretovat – to je jeden z rozdílů oproti symbolickým modelům, u kterých výsledky učení často můžeme interpretovat.

Existuje celá řada typů neuronových sítí a způsobů jejich učení. Zde se podíváme pouze na jeden konkrétní typ – dopředné neuronové sítě a učení s učitelem. Základem modelu je umělý neuron. Ten má několik vstupních spojení (synapsí) od jiných neuronů. Výpočet neuronu se skládá ze dvou kroků: podívá se, zda jsou aktivní neurony, ze kterých vedou vstupní spojení, a podle toho se rozhodne, zda bude v následujícím kroku aktivní či nikoliv. Každé spojení má navíc přiřazenu svoji „synaptickou váhu“, která určuje, jak moc příslušné spojení ovlivňuje rozhodnutí neuronu.


Jakmile máme umělé neurony, umělou neuronovou síť dostaneme snadno – pospojujeme jednotlivé neurony. Často používaná architektura sítě je ilustrována na obr. 8.2. Neurony jsou rozděleny do vrstev, spojení vedou vždy jen mezi dvěma následujícími vrstvami, první vrstva je vstupní (vstup signálu z okolí), další jsou vrstvy skryté a poslední vrstva je výstupní (předání signálu do okolí).

Výpočet sítě probíhá v krocích. Na vstupní vrcholy zavedeme vstupní hodnoty. V každém kroku aktualizujeme hodnotu neuronů podle vstupních uzlů a podle aktivní funkce. Takto se postupně ustálí aktivita neuronů v jednotlivých vrstvách a po konečném počtu kroků se ustálí i hodnota výstupních neuronů.

Fungování neuronové sítě závisí na nastavení synaptických vah. Tyto váhy potřebujeme nastavit tak, aby síť řešila co nejlépe zadaný problém. To neděláme „ručně“, ale pomocí automatického učení. Při „učení s učitelem“ potřebujeme sadu trénovacích příkladů ve formátu: vstup a žádaný výstup. S pomocí těchto dat síť učíme. Začneme s náhodným nastavením synaptických vah. Pro trénovací příklady provedeme výpočet sítě, porovnáme obdržovaný výstup a žádaný vzorový výstup a v případě, že se tyto dva liší, upravíme váhy spojení mezi neurony. Úpravy vah se obvykle provádějí pomocí učení zpětným šířením. Pro každý neuron upravujeme synaptické váhy hran tak, abychom zmenšili velikost chyby (odchyly vypočítané odpovědi od správné odpovědi). S úpravami synaptických vah začínáme u výstupních neuronů, u kterých máme velikost chyby přímo k dispozici. Pro ostatní neurony nemůžeme přímo určit



Obr. 8.2: Dopředná neuronová síť: příklad jednoduché architektury.



Obr. 8.3: Rozpoznávání znaků: příklad správná a poškozená verze písmen A, B.

velikost chyby, protože nevíme, jaká měla být správná hodnota. Pro tyto neurony propagujeme chybu zpětně podél hran od výstupních neuronů – čím větší je synaptická váha, tím víc daný neuron přispíval k chybnému výsledku, a tím větší má tudíž podíl na chybě. Uvedenou proceduru opakujeme na trénovacích datech tak dlouho, dokud se chyba nesníží na přijatelnou mez (což se však někdy nemusí podařit).

Použití neuronových sítí je založeno na jejich schopnosti zobecňování (tj. indukativní přístup) – dobře naučená síť je schopna fungovat nejen na trénovacích datech, na kterých se učila, ale i na nových datech, jež dříve neviděla. Dosáhnout tohoto výsledku však není úplně jednoduché a vyžaduje zkušenosti, protože musíme nastavit parametry učení tak, aby se síť dostatečně naučila, ale současně aby se „nepřeučila“. Přeučení znamená, že síť umí velmi dobře pracovat na trénovacích datech, ale neumí zobecňovat.

Typickou ukázkou použití neuronových sítí je rozpoznávání znaků (obr. 8.3). Úkolem je rozpoznávat znaky, které jsou ručně napsané nebo částečně poškozené. Předpokládejme, že máme rozlišovat k různých znaků, znaky máme reprezentovány v mřížce $n \times m$ polí, každé pole je buď černé, nebo bílé. Pokud používáme výše popsanou architekturu dopředné sítě, máme $n \times m$ vstupních neuronů reprezentujících jednotlivá pole mřížky, vhodný počet skrytých neuronů a k výstupních neuronů. Chceme, aby vždy právě jeden z výstupních neuronů byl aktivní a indikoval, o jaký znak jde. Jako trénovací příklady předkládáme síti neporušené či mírně porušené znaky spolu s informací o správné odpovědi. Jakmile síť na těchto datech naučíme, měla by být schopna rozpoznat i poškozené znaky, které dříve neviděla.

Umělé neuronové sítě se používají především u problémů, u nichž funguje induktivní, ale nikoli deduktivní uvažování. Příklady takových aplikací jsou klasifikace vzorů, rozpoznání obrazů, řeči, zpracování signálů, aproximace funkcí, predikce řad nebo řešení složitých optimalizačních problémů. Pro ilustraci uvedme konkrétní aplikaci – rozpoznávání čisté a naředěné malinové hmoty podle infračerveného spektra, abyste věděli, zda vás dodavatel nešidí (Sangalli, 1998).

Neuronové sítě můžeme použít i jako součást modelů s agenty. Příkladem takového použití je studie vývoje sdíleného slovníku (Hutchins, Hazlehurst, 1995). Model obsahuje skupinu agentů a objektů, o kterých se tito agenti vyjadřují. Každý agent má svoji vlastní neuronovou síť, která funguje jako paměť pro zapamatování jmen objektů. Na začátku simulace si každý agent vytvoří své vlastní názvy pro objekty – to odpovídá tomu, že síť inicializujeme náhodnými hodnotami a pak ji necháme naučit se spolehlivě rozlišovat mezi jednotlivými objekty. Poté přichází na řadu interakce: vybereme vždy dva agenty a jeden objekt, agenti si vzájemně vymění svoje názory na název objektu a poté se trochu „přeučí“, tj. upraví svoji neuronovou síť tak, aby vzali názor druhého agenta v potaz. Tímto způsobem jsou agenti schopni dospět ke sdílenému slovníku, tj. všichni používají stejné názvy pro objekty.

Souvislosti: Zde nastíněná architektura a způsob učení jsou asi nejčastěji používané, nicméně jde pouze o jeden z mnoha modelů umělých neuronových sítí. Detailnější, ale stále relativně stručný a čtivý popis základů neuronových sítí nabízí např. Mařík et al. (1997), Flake (2000), Sangalli (1998), Gilbert, Troitzsch (2005). Detailnější a teoretičtější popis pak dává např. Šíma a Neruda (1996).

8.3 Simulovaná evoluce

Ty se díváš na věci a říkáš: „Proč?“ Já ale sním o věcech, které nikdy nebyly, a ptám se: „Proč ne?“ (G. B. Shaw)

V teorii her studujeme, jaká akce je pro jedince optimální, přičemž abstrahujeme od toho, jak k této akci jedinec dospěje (resp. předpokládáme, že je natolik racionální, že optimální řešení odvodí). Nyní se na problém podíváme z druhé strany – nebude nás ani tak zajímat, co je optimální, jako to, jakým způsobem se k tomu dospěje. Začneme evolučním pohledem.

Biologická evoluce

Slepice je jenom způsob, jakým vajíčko vyrábí další vajíčko. (S. Butler)

Než představíme model, shrneme základní informace o biologické evoluci. Především je důležité si uvědomit, že u evoluce mluvíme o vývoji populace jako celku, a nikoliv o vývoji konkrétních jednotlivců. Evoluce je postavena na dvou základních mechanismech: výběr a dědičnost. Princip výběru je shrnut známým sloganem

„přežití nejsilnějších“. Výstižnější charakterizací je však spíše „přežití schopných reprodukce“. Za pozornost stojí například fakt, že všichni naši předci žili tak dlouho, že se stihli reprodukovat, a to není jen tak! Výběr zajišťuje, že vlastnosti užitečné pro přežití se přenášejí dále, kdežto vlastnosti neužitečné nebo dokonce škodlivé zmizí spolu se svým nositelem. Jde o systém dominovaný pozitivní zpětnou vazbou – i malá výchylka (mutace), která způsobí vznik užitečné vlastnosti, se v populaci rychle rozšíří, a tak dochází k vývoji.

Druhou základní složkou je dědičnost, která umožňuje, aby se ony užitečné vlastnosti, jež posloužily k přežití rodičů, předaly i na potomky. Dědičnost funguje na základě předávání genetické informace uložené v molekule DNA, což je řetězec složený ze čtyř základních bloků (adenine, cytosine, guanine, thymine). Přesné fungování dědičnosti, DNA, genů, chromozomů a související biologické mašinerie je komplikované a nebudeme ho rozebírat. Pro vytvoření abstraktního modelu evoluce jsou důležité pouze následující principy:

- DNA můžeme chápat jako řetězec znaků.
- DNA se umí kopírovat, kopírování je velmi spolehlivé, nicméně s velmi malou pravděpodobností dochází k náhodným mutacím.
- Při reprodukci dochází ke kombinaci (křížení) DNA rodičů.

Na potomky se přenáší pouze genetická informace, schopnosti získané během života se nepřenášejí. Toto je důležitý bod, který zdaleka není zřejmý. Například Lamarckův model evoluce, který předcházel Darwinovu teorii, předpokládal, že schopnosti získané za života se předávají potomkům. Ačkoliv nepřenášení získaných schopností je jeden z typických rysů biologické evoluce, při simulované evoluci může být výhodné tento rys opustit.

Genetické algoritmy

Přírodní výběr je mechanismus pro generování mimořádně velkého stupně nepravděpodobnosti. (R. Fisher)

Existuje celá řada modelů inspirovaných biologickou evolucí. Jednoduché modely zohledňují pouze princip přežití nejsilnějších bez vývoje, tyto modely jsou přesněji nazývány jako ekologické modely. Složitější a užitečnější modely zohledňují jak princip přežití nejsilnějších, tak i vývoj (křížení, mutace). Mezi takové modely patří například genetické algoritmy, evoluční programování, genetické programování. Tyto přístupy, většinou vyvinuté nezávisle na sobě, se liší především způsobem reprezentace a provedením dílčích operací, základní myšlenky jsou velmi podobné.

Zde popíšeme základní myšlenku genetických algoritmů. Nejdříve musíme ujasnit způsob reprezentace jedinců – k tomu se většinou používají řetězce, protože se s nimi jednoduše provádějí další potřebné operace. Řetězec musí jednoznačně popisovat studované vlastnosti jedince. Křížení probíhá prostým prohozením dvou částí řetězce. Kromě tohoto základního křížení je možno použít různé variace jako například vícebodové křížení či křížení, které zachovává základní bloky. Může být rovněž potřeba používat speciální formy křížení, abychom zachovali požadovanou vlastnost řetězců.

Mutace je prováděna jako náhodná změna v řetězci, případně mohou být opět zapotřebí speciální úpravy. Mutace většinou nevede ke zlepšení, může však pomoci překonat lokální optima (stavy, které nejsou optimální, ale nelze je vylepšit žádnou malou změnou). Proto jsou mutace používány, ale pouze s malou pravděpodobností.

Základní princip genetického algoritmu vystihuje následující pseudokód:

- Vyber počáteční populaci P .
- Opakuj podle potřeby:
 - vytvoř novou prázdnou populaci P' ,
 - opakuj, dokud P' není plná:
 - * vyber dva jedince z populace P v závislosti na kritériu zdatnosti,
 - * volitelně proved' křížení jedinců a nahraď je jejich potomky,
 - * volitelně proved' mutace,
 - * přidej jedince do populace P' ,
 - proved' $P := P'$.

Výběr jedinců pro křížení je založen na měřítku zdatnosti. Pokud nemáme k dispozici žádné absolutní měřítko, necháme jedince spolu soutěžit (čímž dochází ke ko-evoluci). Kdybychom používali striktně deterministický výběr nejlepších, pak by to vedlo ke ztrátě diverzity populace a pravděpodobně k uváznutí na lokálním minimu. Proto používáme spíše náhodný výběr, který přihlíží k zdatnosti (šance na výběr je úměrná zdatnosti).

Pro genetické algoritmy je důležité správné nastavení parametrů (velikost populace, pravděpodobnost křížení, mutací, kritéria výběru). Pro velikost populace se používají následující dvě základní pravidla: součin velikosti populace a počtu simulovaných generací by měl být větší než 100 000, velikost populace by měla být výrazně větší než počet použitých genů (tj. délka řetězce popisující jedince).

Souvislosti: Ke genetickým algoritmům existuje velmi rozsáhlá literatura, z prací, které mají přehledový charakter a mají blízko k modelování, například Flake (2000), Sangalli (1998) a Gilbert a Troitzsch (2005).

Příklad a aplikace

Klasickým příkladem ilustrujícím evoluční vývoj je příklad můry *Biston betularia* (Krebs, 2001). Tato můra je bílá s černými skvrnami na křídlech. V polovině devatenáctého století se v Anglii objevila černá odrůda této můry. V té době se v Anglii rozbíhala průmyslová revoluce a s ní související znečištění. Kvůli tomu umíraly lišejníky rostoucí na kůře stromů. Černá můra byla na tmavých, mrtvých lišejnicích méně vidět než bílá, takže černá forma můry začala postupně v populaci dominovat. V posledních 50 letech průmyslové znečištění pokleslo a opět začíná převládat bílá forma.

Tento scénář můžeme zachytit pomocí genetického algoritmu. U jedinců budeme kódovat pouze jejich barvu, kterou reprezentujeme řetězcem (například pomocí RGB

kódu). Křížení a mutace provádíme s tímto řetězcem přímočaře. Zdatnost vyjádříme jako rozdíl barvy jedince oproti zadané barvě kůry.

Mezi typické reálné aplikace genetických algoritmů patří: složité optimalizační problémy (problém obchodního cestujícího, rozvrhování), učení a plánování (robotika, hry), návrh systémů (hardware, materiály). Jak ukážeme v následujících kapitolách, genetické algoritmy můžeme zapojit také do modelování a používají se rovněž jako součást klasifikačních systémů, což je další z formalismů pro modelování myšlení a adaptace.

Souvislosti: Knihovna nástroje NetLogo (Wilensky, 1998) obsahuje model podobného typu, jako je popsán příklad s mûrami. Další aplikace genetických algoritmů pro modelování jsou uvedeny v kapitole 12.2 (model evoluce digitálních organismů), v kapitole 14.2 (vývoj strategií při hře Dilema vězně) a v kapitole 13.2 (vývoj agentů obchodujících na umělém trhu).

8.4 Shrnutí

- Modely myšlení a vývoje slouží třem účelům: pochopení fungování přírodních mechanismů, vylepšení modelů komplexních systémů (např. obohacení modelů s agenty) a nové metody řešení náročných výpočetních problémů (např. aplikace v umělé inteligenci).
- Teorie her je vhodná především pro modelování strategického rozhodování za předpokladu racionality.
- Existují dva základní přístupy k modelování myšlení: symbolický a konekcionistický.
- Typickým příkladem symbolického modelování jsou produkční systémy, které jsou založeny na pravidlech typu **IF-THEN**. Model se učí pomocí změny priorit pravidel a pomocí vývoje pravidel nových.
- Typickým příkladem konekcionistického modelu jsou umělé neuronové sítě, které napodobují fungování mozku a jsou tvořeny sítí umělých neuronů. Učení probíhá pomocí změny vah spojení mezi jednotlivými neurony v síti.
- Genetické algoritmy fungují na principech inspirovaných evolucí: výběr nejzdatnějších a reprodukce s využitím křížení a mutací. Při použití genetického algoritmu začneme s velkou populací potenciálních řešení a postupně vyvíjíme lepší řešení.
- Vývoj, učení a adaptace jsou často řízeny zpětnou vazbou mezi činností agenta a prostředím. Ke zlepšování (vývoji, učení) v takovém případě dochází díky informaci o úspěšnosti, kterou agent dostává od prostředí.
- Ač jsou uvedené formalismy značně rozlišné, všechny jsou nějakým způsobem postaveny na paralelismu a vzájemném propojení mnoha jednoduchých dílčích prvků.

9 Komplexní síť

M: Králíci jsou všude! Tak třeba Bob a Bobek, Bílý králík v Alence v říši divů, Bugs Bunny, Králíček v Medvídkovi Pú. Navíc mezi nimi existuje spousta souvislostí. Sleduj, udělal jsem síť králíků. Jsou tady všichni vypsaní a spojení čarou, když mezi nimi existuje souvislost. Tak třeba Bílý králík vystupuje nejen v Alence, ale i v Matrixu. Bob a Bobek jsou také bílí králíci, uvědomil sis to někdy? Je to celé úžasně propojené, mezi každými dvěma králíky najdeš spojitost jen na pár mezičlánků.

S: Víš o tom, že to funguje nejen u králíků, ale i u lidí? Kdyby sis nakreslil všechny lidi a pospojoval čarou ty, kdo se vzájemně znají, dostal bys podobný propletenec. Dokonce se říká, že každé dva lidi lze spojit na průměrně šest mezikroků.

M: Tak to je dobrá náhoda, že králíci a lidi jsou na tom skoro stejně.

S: Kdepak, to není žádná náhoda. Podobné vlastnosti totiž fungují nejen pro králíky a lidi, ale i pro spoustu dalších sítí – například internetové stránky, vztahy mezi proteiny nebo slovy v jazyce. Na všechny se můžeme dívat jako na síť – uzly spojené hranami. Jak si myslíš, že taková síť vypadá?

M: Když říkáš, že podobně jako moje síť králíků, tak asi dost náhodně. Žádnou jasnou strukturu to mít nebude.

S: Máš pravdu, že tam není žádná jasná struktura. Úplně náhodné ale taky nejsou. Proto se těmto sítím říká komplexní síť. Ukazuje se, že všechny ty rozdílné sítě mají spoustu společných vlastností. Navíc tyto společné vlastnosti umíme zachytit modely.

M: Co tady s tím mají společného modely?

S: Tvá nedůvěřivost je částečně na místě. Tady jde o jiný typ modelování, než jsem ti ukazoval doposud. Nemodelujeme konkrétní systém, ale obecný jev, tedy vlastnost společnou mnoha systémům. Jde o podobný typ modelu, jakým jsou fyzikální zákony. Například Newtonův gravitační zákon nemodeluje gravitační působení mezi jablkem a Zemí, ale obecně mezi dvěma předměty.

M: No dobře, ale k čemu mi jsou modely sítí? Newtonův zákon se hodí znát, to je jasné. Když si králík potřebuje spočítat, jak moc se má odrazit, aby přeskočil potok, hned ví, čeho se chytnout. Ale k čemu je model komplexní sítě?

Tabulka 9.1: Příklady komplexních sítí.

Oblast	Uzly	Hrany
web	stránky	odkazy
internet	servery	dráty
vědecká spolupráce	vědci	spoluautorství
síť herců	herci	hráli v jednom filmu
citační síť	vědecké články	citace
potravní řetězce	druhy zvířat	vztah lovec-kořist
síť sexuálních kontaktů	lidé	měli spolu sex
metabolismus	chemické látky	vystupují ve stejné reakci
lingvistika	slova	konotace, synonyma
telefonní hovory	telefony	volání
elektrická síť	elektrárny, transformátory	dráty
neuronové síť	neurony	synaptické spojení

S: Na sítích probíhá spousta jevů, kterým bychom rádi rozuměli – například vyhledávání informací, toky energie nebo šíření epidemií. Pomocí modelů se můžeme pokusit porozumět těmto jevům.

M: Neměl bys nějaký příklad s králíky?

S: Uvaž takový ekosystém. Na ten se můžeme podívat také jako na komplexní síť, ve které jednotlivé druhy představují uzly. Dva uzly jsou spojeny hranou, pokud se jeden druh živí tím druhým, takže například z uzlu liška vede hrana do uzlu králík. A teď nás může zajímat, co se stane, když nějaký druh vyhubíme. Jaký dopad to bude mít na zbytek té sítě? Vyhynou další druhy, nebo se naopak někdo přemnoží? Pro odpovězení těchto otázek potřebujeme dobře rozumět celkové struktuře sítě.

9.1 Úvodní poznámky

Pod pojmem komplexní sítě rozumíme složitý graf reprezentující vztahovou vlastnost, přičemž pojem složitosti zde používáme ve významu, jaký jsme uvedli v kapitole 2, tj. ani pravidelný, ani náhodný, a tím pádem náročný na popis. Příklady komplexních sítí uvádíme v tabulce 9.1. Při analýzách ignorujeme specifika jednotlivých uzlů a sítě považujeme za holý graf, tj. za množinu uzlů (lidé, geny, počítače) a hran (známosti, exprese, dráty). Ukazuje se, že tyto sítě mají mnoho společných vlastností bez ohledu na to, z jaké oblasti pocházejí. V této kapitole uvedeme ony společné vlastnosti a představíme abstraktní modely, jejichž cílem je tyto vlastnosti postihnout.

Až do 90. let byly jako model komplexních sítí používány náhodné grafy. Bylo jasné, že komplexní sítě nemají žádnou jasnou pevnou strukturu a sítě byly příliš velké na systematické zpracování. Náhodný graf tak byl přirozeným modelem. V druhé polovině 90. let začala být data o komplexních sítích dostupná v elektronické podobě a bylo možné je začít jednoduše zpracovávat počítačově. Analýzy ukázaly, že

komplexní sítě mají mnoho zajímavých společných vlastností, a byly navrženy první abstraktní modely. Nyní tato oblast výzkumu prudce expanduje a mluví se o rodící se vědě sítí (network science).

Na úvod kapitoly stručně připomeneme základní pojmy teorie grafů, které dále používáme. Uvádíme pouze stručné definice bez příkladů, v případě potřeby čtenář najde detailnější vysvětlení v kterékoli základní učebnici teorie grafů.

Graf je dvojice (V, E) , kde V je množina uzlů a E je množina hran. Rozlišujeme dva základní typy grafů: orientované grafy, kde $E \subseteq V \times V$, a neorientované grafy, kde $E \subseteq \binom{V}{2}$. V této kapitole se budeme pro zjednodušení zabývat pouze neorientovanými grafy. Další pojmy:

- cesta v grafu: posloupnost uzlů, kdy jsou každé dva sousední uzly spojeny hranou,
- vzdálenost uzlů u a v : délka nejkratší cesty mezi u a v ,
- stupeň uzlu v : počet hran vycházejících z vrcholu v ,
- distribuce stupňů $P(k)$: pravděpodobnost, že náhodně vybraný uzel má stupeň k .

Souvislosti: Populárně psaný přehled výzkumu komplexních sítí a popis základních vlastností a modelů podává Barabási (2002). Detailnější technický přehled poskytují například sborníky editované Bornholdtem a Schusterem (2003) a Newmanem et al. (2006). Mezi klasické články z této oblasti patří příspěvky od Alberta a Barabásiho (2002) a Strogatze (2001). Úvod do praktické analýzy komplexních sítí (s důrazem na sociální sítě) nabízí Nooy et al. (2005).


9.2 Vlastnosti komplexních sítí

Zmínili jsme, že komplexní sítě mají společné vlastnosti. O jaké vlastnosti tedy jde?

Malý svět

První typická vlastnost komplexních sítí se nazývá „fenomén malého světa“. Název souvisí se zkušeností, kterou má asi většina lidí – potkáte cizího člověka, kterého jste nikdy neviděli, a po chvíli povídání zjistíte, že máte společné známé, a tak prohlásíte „ten svět je ale malý“. Přesněji řečeno tato vlastnost vyjadřuje, že mezi (skoro) každými dvěma uzly vede krátká cesta, přičemž pod pojmem „krátká cesta“ rozumíme cestu řádově menší než velikost sítě.

Vlastnost malého světa bývá rovněž označována termínem „šest stupňů odloučení“. Tento název odkazuje na známý experiment, který provedl sociolog Stanley Milgram v roce 1967. Milgram na jednom konci USA (v Kansasu) rozdával lidem 60 balíčků, které byly adresovány osobě na druhém konci USA (v Massachusetts). Na balíček bylo uvedeno pouze jméno, město a zaměstnání, nikoliv adresa. Balíčky dále obsahovaly instrukci, že každý smí zásilku poslat jen někomu, s kým se osobně zná. Cílem bylo dostat je co nejrychleji na místo určení. Balíčky, které dorazily až



Obr. 9.1: Koeficient shlukování: příklady.

k adresátovi, přišly jen na několik kroků – průměrně šest. Z tohoto výsledku pramení hypotéza „šesti stupňů odloučení“ – každé dva lidi lze spojit řetězcem známostí průměrné délky šest. O této hypotéze vznikla i divadelní hra a celovečerní film, čímž se dostala do obecného povědomí. Milgramův experiment a způsob jeho vyhodnocení měl sice několik metodických chyb, nicméně později byla provedena řada dalších experimentů (např. s posiláním e-mailů), které hypotézu dále potvrdily.


Vlastnost malého světa je přítomna nejenom v sociální síti, ale i v ostatních komplexních sítích (průměrná délka cesty se samozřejmě liší). Vlastnost malého světa je však přítomna i v náhodných grafech, takže to není něco, co by odlišovalo komplexní síť od náhodných grafů.

Shlukování

Další typický jev pro sociální síť je shlukování. Lidé mají tendenci tvořit skupinky. Pokud já znám Pepu a Frantu, je dost pravděpodobné, že se Pepa s Frantou vzájemně znají. Tento jev se opět vyskytuje nejen v sociálních sítích, ale i v mnohých jiných komplexních sítích.

Formálně se shlukování vyjadřuje pomocí koeficientu shlukování, který udává poměr počtu propojených sousedů uzlu ku počtu všech možných dvojic sousedů (viz obr. 9.1). Jako charakteristiku sítě pak používáme průměrný shlukovací koeficient. Tato charakteristika již jednoznačně odlišuje komplexní síť od náhodných grafů, protože zatímco náhodné grafy mají koeficient blízký nule, komplexní síť jej mají vyšší.

Koeficient shlukování pouze vyjadřuje, že se uzly v grafu nějak shlukují, ale nevyjadřuje jak. Lokální strukturu grafu můžeme studovat podrobněji a zaměřit se na takzvané motivy. Motiv grafu je podgraf, který se vyskytuje daleko častěji než v náhodném grafu. V tomto případě neexistuje žádný motiv, který by byl typický všem komplexním sítím. Většina komplexních sítí má však své charakteristické motivy a síť ze stejné oblasti (např. biologické síť) navíc tyto motivy často sdílí.



Obr. 9.2: Srovnání Poissonovy distribuce a mocninného zákona.

Bezškálovitost

Třetí charakteristická vlastnost komplexních sítí je specifická distribuce stupňů jednotlivých uzlů, tj. kolik uzlů má jaký stupeň. Nejklasičtější distribuce, se kterou jsme zvyklí pracovat, je Gaussova (normální) distribuce, která popisuje například rozložení výšky lidí v populaci nebo očekávaný počet orlů při hodu mincí. U této distribuce máme typickou hodnotu (výška 170 cm, 50 % orlů), kolem které jsou ostatní hodnoty rovnoměrně rozloženy. Podobné vlastnosti má Poissonova distribuce, která popisuje distribuci stupňů uzlů v náhodných grafech. Komplexní sítě však vykazují jinou distribuci – mocninný zákon vyjádřený vztahem $P(k) \sim k^{-\gamma}$. Obr. 9.2 ilustruje rozdíl mezi těmito dvěma typy distribucí.

Distribuce podle mocninného zákona je charakteristická existencí velmi mnoha prvků s nízkou frekvencí výskytu a několika málo prvků s vysokou frekvencí výskytu. Tato distribuce není tolik známá jako třeba normální distribuce, ale v komplexních systémech se vyskytuje velmi často. Uvedme několik příkladů: velikost meteoritů, záplav, požárů a zemětřesení, frekvence použití písmen a slov v jazyce, frekvence not v hudebních skladbách, frekvence jmen v populaci, rozdělení bohatství ve společnosti, velikost měst.

Většina komplexních sítí vykazuje rozložení stupňů podle mocninného zákona, tj. existuje několik hodně propojených uzlů, zatímco většina uzlů má malé propojení. Příklady: webové stránky (pár často odkazovaných stránek, většina jen málo), citační

sítě (pár často citovaných článků, většina jen málo), sociální sítě (pár velmi známých lidí, většina jen málo).

Jak je vidět na obr. 9.2, zatímco Poissonova distribuce má typickou hodnotu (škálu), v distribuci podle mocninného zákona taková hodnota chybí. Proto sítě, jejichž distribuce stupňů odpovídá mocninnému zákonu, nazýváme bezškálovité (v češtině není zatím tento výraz příliš zaužívaný, jde o překlad anglického termínu „scale-free“).

9.3 Modely komplexních sítí

Uvedli jsme konkrétní příklady komplexních sítí a vlastnosti, které mají sítě společné. Nyní se podíváme na abstraktní modely sítí a na to, do jaké míry modely reprodukují zmíněné vlastnosti. Popsané modely jsou natolik jednoduché, že je často možné je přesně matematicky analyzovat, nicméně i v těchto případech nám počítačová simulace zkoumání modelů výrazně usnadňuje.

Náhodné grafy


Základním modelem komplexních sítí jsou náhodné grafy. Většinou se používá Erdős-Renyi model: zvolíme množinu vrcholů V a počet hran n , poté z množiny všech potenciálních hran $\binom{V}{2}$ vybereme náhodně n hran. Případně lze použít alternativní definici, která je zhruba ekvivalentní. Zvolíme množinu vrcholů V a pravděpodobnost p a pro každou dvojici vrcholů vložíme hranu s pravděpodobností p .

Náhodné grafy mají mnoho zajímavých vlastností, kvůli kterým je matematici intenzivně studují. Na náhodných grafech se například často projevuje princip fázevého přechodu. Pokud si zvolíme vlastnost grafu (například spojitost grafu) a uvážíme grafy s pravděpodobností hran p , pak buď téměř všechny danou vlastnost (např. spojitost) mají, nebo ji téměř všechny nemají. K přechodu mezi těmito dvěma režimy dochází prudce se změnou parametru p . Vlastností tohoto typu matematici studují celou řadu, nicméně jejich význam pro porozumění reálným sítím je přinejmenším sporný.

Podívejme se, jak náhodné grafy reprodukují typické vlastnosti komplexních sítí. Průměrná délka cesty v náhodném grafu odpovídá logaritmu z celkového počtu uzlů, což splňuje požadavek malého světa. Ovšem distribuce stupňů odpovídá Poissonově distribuci, a nikoliv mocninnému zákonu a průměrný shlukovací koeficient je výrazně menší než u reálných komplexních sítí. Takže náhodné grafy zdaleka nezachycují vlastnosti komplexních sítí.

Grafy malého světa

Jedním z prvních modelů, které se snažily zachytit vlastnosti komplexních sítí, byl model zvaný „grafy malého světa“ (též zvaný Watts-Strogatz model). Model je založen na následujících pravidlech:



Obr. 9.3: Ilustrace modelu grafů malého světa (podle Watts, 2003).

1. Pravidelné základní uspořádání. Vezmeme N vrcholů, uspořádáme je do kruhu a každý spojíme s K sousedy ($K/2$ na každé straně).
2. Proces náhodné změny hran. S pravděpodobností p každou hranu nahradíme jinou, náhodnou hranou.

Obr. 9.3 znázorňuje přechod od pravidelnosti k náhodě, který dostáváme s měnícím se parametrem p . Pro $p = 0$ dostáváme úplně pravidelný graf, který vykazuje velké shlukování, má však dlouhé délky cest. Pro $p = 1$ dostáváme úplně náhodný graf, který má krátké cesty, avšak postrádá shlukování. Pro vhodnou volbu parametru p dostáváme grafy, které mají současně shlukování a krátké cesty.

Tento model tedy dobře postihuje dva hlavní aspekty komplexních sítí, liší se však od nich v distribuci stupňů. Přesná charakterizace distribuce stupňů je složitá, v principu však dostáváme podobnou distribuci jako pro náhodné grafy, tj. jinou než u reálných komplexních sítí.

Bezškálovité sítě

Nejznámější model, který reprodukuje distribuci uzlů podle mocninného zákona, je model bezškálovité sítě (též zvaný Barabási-Albert model). Model je založen na následujících pravidlech:

1. Začneme s malým množstvím vrcholů a hran.
2. Postupně přidáváme vrcholy. Nově přidaný vrchol spojíme k hranami s již existujícími vrcholy.
3. Při výběru vrcholů dodržujeme upřednostněné připojení. Pravděpodobnost, že vrchol vybereme, je přímo úměrná jeho aktuálnímu stupni, konkrétně pravděpodobnost výběru uzlu se stupněm k_i je $k_i / \sum k_j$.

Jaké jsou vlastnosti tohoto modelu? Průměrná délka cesty je opět $\log N$, tj. dostáváme krátké cesty. Díky upřednostněnému připojení v modelu funguje princip „bohatší se stávají bohatšími“ a distribuce stupňů tak odpovídá mocninnému zákonu. Pro základní model, tak jak jsme si ho představili, jde o distribuci s fixním $\gamma = 3$ (nezávisle na parametru k). Koefficient shlukování je větší než u náhodných

grafů, je však menší než u reálných sítí a navíc klesá s velikostí grafu (na rozdíl od reálných sítí a modelu malého světa).

Proti předchozím dvěma modelům je zde důraz na vznik (růst) sítí – žádaná struktura přitom vzniká jako vedlejší produkt. Díky pravidlu upřednostněného připojení je model řízen pozitivní zpětnou vazbou, která dává vzniknout distribuci podle mocninného zákona. Přítomnost dominantní pozitivní zpětné vazby je ostatně charakteristická pro všechny systémy vykazující přítomnost mocninného zákona.

Existují mnohá rozšíření tohoto základního modelu, která zachovávají základní princip postupného vývoje, ale dále rozvíjejí různé detaily, např. používají různé jiné funkce pro upřednostněné připojení. Existují také modely, které se snaží zohlednit jak shlukování, tak distribuci podle mocninného zákona. Do těchto detailů však zde nezacházíme.

9.4 Procesy na sítích

Komplexní sítě mají tedy zajímavé vlastnosti a máme modely, které tyto vlastnosti do určité míry reprodukuje. K čemu je to však dobré? Můžeme znalosti o sítích a jejich abstraktní modely využít? Můžeme – typickou aplikací je zkoumání procesů na sítích. K tomu využíváme většinou počítačové simulace s využitím uvedených modelů.

Zde stručně ilustrujeme způsob aplikace na příkladě robustnosti sítí a na vyhledávání v sítích. Další procesy, které se na sítích studují, jsou například šíření epidemií, formování názorů, dynamika spolupráce a soutěže, ekonomické aktivity nebo synchronizace.


Souvislosti: V kapitole 11.2 je uveden model šíření epidemie na sítích.

Robustnost sítí

Jak se změny vlastností sítě (například spojitost nebo průměrná vzdálenost) při odstranění určitých uzlů? Schopnost sítě zachovávat svoje vlastnosti i při změnách nazýváme robustnost. Robustnost sítí je velmi důležitá – stačí si uvědomit význam tohoto pojmu pro příklady, jako je ekosystém, ekonomická síť firem nebo internet.

Jaký vliv na robustnost má topologie sítě? Obr. 9.4 ukazuje výsledky experimentu porovnávajícího robustnost bezškálovitých sítí a náhodných grafů (Albert et al., 2000). Při tomto experimentu byly rozlišeny dva typy výpadků: chyby (= náhodně odstraněné uzly) a útoky (= cíleně odstraněné uzly s největším stupněm). Obrázek ukazuje, jak se mění průměr sítě v závislosti na počtu odstraněných uzlů. Vidíme, že bezškálovité sítě mají podstatně vyšší odolnost proti chybám než náhodné grafy, avšak současně jsou bezškálovité sítě podstatně náchylnější proti útokům než sítě náhodné.

Popsané charakteristiky (odolnost proti chybám, náchylnost k útokům) byly podrobněji studovány nejen na modelech, ale i na konkrétních komplexních sítích, například na komunikačních sítích (internet, www), ekonomických sítích (teroristický



Obr. 9.4: Odolnost vůči chybám a útokům (podle Albert et al., 2000).

útok na New York), náboženských sítích ve středověku (útoky zde představují zásahy inkvizice) a na sítích vztahů mezi proteiny (princip ukazuje, proč je funkčnost vysoce propojených proteinů životně důležitá).

Hledání v grafu

Většina reálných sítí má vlastnost malého světa, tj. mezi většinou uzlů existují krátké cesty. Ovšem jak tyto cesty najít? Všimněme si, že u Milnerova experimentu nejen že existuje krátký řetězec znalostí, ale účastníci experimentu jej byli schopni najít bez znalosti celého grafu jen za použití lokálních informací.

Tento problém částečně řeší Kleinbergův model (Kleinberg, 2002). Graf je založen na dvourozměrné mřížce, do které jsou náhodně přidány dlouhé vazby (podobně jako u modelu malého světa). Uzly mají k dispozici informace o svojí poloze a o poloze svých sousedů v mřížce. Ukazuje se, že tato lokální informace stačí pro efektivní globální navigaci směrem k cíli.

Pokud graf nemá žádnou strukturu, které bychom se mohli při hledání chytit, nezbyvá nám než prohledávat graf pomocí náhodné procházky. Náhodná procházka vždy vybírá další uzel pro navštívení čistě náhodně. V případě grafů s bezškálovitým rozložením stupňů však můžeme tuto strategii vylepšit tak, že cíleně preferujeme uzly s vyšším stupněm. Simulace na modelech bezškálovitých sítí ukazuje, že takto upravená náhodná procházka dosahuje lepšího pokrytí než čistě náhodná procházka. Tento přístup byl aplikován u systému Gnutella, což je distribuovaný decentralizovaný systém pro sdílení dat (Bornholdt, Schuster, 2003).

9.5 Shrnutí

- V případě modelů komplexních sítí nemodelujeme konkrétní systém, ale obecný jev, podobně jako v případě fyzikálních zákonů.
- Příklady komplexních sítí jsou sociální síť, interakce mezi proteiny a internet.
- Komplexní síť mají společné vlastnosti, mezi něž patří malé vzdálenosti, shlukování a bezškálovité rozložení stupňů uzlů.
- Představili jsme jednoduché abstraktní modely komplexních sítí: náhodné grafy, modely malého světa a bezškálovité síť.
- Pomocí těchto modelů můžeme zkoumat procesy probíhající na sítích a vliv topologie sítě na tyto procesy. Příklady procesů na sítích jsou útoky, chyby, vyhledávání nebo šíření epidemie.

10 Metody analýzy modelů

M: Už to modelování úplně zvládám. Sleduj moje modely. Tady mám model králíků u babičky na zahradě, tady jsou králíci a lišky a tady model vývoje dlouhých uší u králíků. Všechno mi pěkně funguje, teď akorát naskládám výsledky do seminárky.

S: Počkej, tentokrát bys měl přibrzdit ty. Teď máš za sebou část modelovacího procesu. Zapomněl jsi, co jsem ti říkal na začátku? Těžiště modelování spočívá v důkladné analýze.

M: A co bych měl analyzovat? Vždyť z toho mám pěkné výstupy – tady použiju graf počtu králíků v čase a tady obrázek rozmístění králíků v prostoru. A je to.

S: Především bys měl pořádně zkontrolovat, jestli jsou modely opravdu v pořádku. Pusť mě k tomu. Sleduj, tady jsem nastavil porodnost na nula a králíkům se nějak nechce vyhnout. To jsem nevěděl, že babička má nesmrtelné králíky.

M: Ježda, to bude nějaký drobný překlep, to hned opravím.

S: Takže především bys měl pořádně a systematicky zkontrolovat, jestli tam nemáš pár dalších drobných překlepů. Pak bys měl modely důkladněji analyzovat.

M: Ale vždyť jsem ti ukazoval graf, který znázorňuje, jak se velikost populace vyvíjí během času. Jak jinak mám model analyzovat?

S: Zobrazení časové osy je sice nejběžnější, ale jen jeden z mnoha možných způsobů zobrazení chování modelu. Můžeš si třeba vynést do grafu proti sobě počet králíků a počet lišek. Pak se dívám, že máš v modelu hodně parametrů. Víš, které z nich jsou důležité? Co když změním hodnotu parametru o 10 %? Bude se model pořád chovat podobně, nebo se výsledky výrazně změní? Co by to znamenalo?

M: No dobře, zkusím tedy spustit simulace s různými hodnotami parametrů a pak výsledky analyzovat. Ještě něco?

S: Ještě bys mohl, když už ten model máš, zkusit různé zásahy za běhu. Uvažme třeba ten model babiččiných králíků. Můžeš vyzkoušet různé strategie chovu králíků. Zkus třeba porovnat, jak to dopadne, když dědeček zabije jednoho králíka každý měsíc a když udělá jedna velká jatka na podzim.

10.1 Úvodní poznámky

V této kapitole nabízíme přehled metod analýz modelů. Většinou se zabýváme obecnými technikami a nezacházíme příliš do detailů specifických pro určité modelovací přístupy. Cílem kapitoly není vysvětlit všechny detaily, ale přesvědčit čtenáře, že důkladné analýzy jsou potřeba. Za tímto účelem uvádíme dva velmi jednoduché modely a na těchto modelech ukazujeme příklady analýz, jež naznačují, kolik toho skrývají i takto jednoduché modely. Jako příklady využijeme klasické jednoduché modely vztahu lovec–kořist, které už byly zmíněny v předchozích kapitolách. Pro srovnání použijeme jak model systémové dynamiky, tak model s agenty.

Systémový model

Z oblasti systémové dynamiky použijeme model popsáný v části 6.2. Připomeňme, že tento model se nazývá Lotka-Voltera model a že ho lze zapsat dvěma diferenciálními rovnicemi:

$$dL/dt = p_l K L - u_l L$$

$$dK/dt = p_k K - u_k K L$$

Chování modelu je udáno počátečními hodnotami proměnných K a L a hodnotami parametrů p_l, p_k, u_l, u_k . Dále v této kapitole jej označujeme jako „systémový model“.

ABM model

V případě modelu s agenty uvážíme model králíků (lovců), kteří žerou trávu (kořist). Prostředí modelu tvoří mřížka 75×75 polí. Na každém poli roste tráva, tráva náhodně dorůstá, dorůstá tím víc, čím víc je trávy v bezprostředním okolí. Agenti-králíci se řídí následujícími pravidly:

- Pohybují se náhodně.
- Sežerou vždy všechnu trávu na poli, na kterém zrovna stojí.
- Ze sežrané trávy získávají energii, za pohyb energii ztrácí.
- Pokud energie klesne na nulu, umírají.
- Pokud energie stoupne nad určitý limit, tak se rozmnoží (rozdělí se na dva králíky s poloviční energií).

Model má čtyři parametry:

- limit, při kterém se králíci množí,
- maximální množství trávy na jednom políčku,
- délka jednoho kroku králíka (o kolik polí maximálně se může pohnout),
- rychlost dorůstání trávy.

Dále v této kapitole označujeme tento model jako „ABM model“.

Souvislosti: Testování modelů a kontrole validity věnuje celou jednu rozsáhlou kapitolu Sterman (2000), výklad je zaměřen především na modely systémové dynamiky. Alespoň stručné metodické rady k přípravě a analýze modelů s agenty obsahuje většina knih z této oblasti (převážně jde o přílohu samotného textu). Jednotlivé knihy jsou často zaměřeny na konkrétní oblast, například sociální vědy (Axelrod, 1997a), (Miller, Page, 2007) nebo ekologii (Grimm, Railsback, 2005). Ellner a Guckenheimer (2006) rozebírají analýzy matematických modelů. Konkrétní ukázkový rozbor provedení analýzy modelu systémové dynamiky uvádí například Deaton a Winebrake (1997). Epstein (2006) uvádí rozbor několika rozsáhlých modelů s agenty z oblasti sociálních věd, tyto modely jsou většinou dobře a zajímavě analyzovány.

10.2 Verifikace a validace modelu

Než se pustíme do důkladných analýz modelu, musíme ověřit, zda model opravdu dělá, co má. Cizími slovy se tato fáze označuje jako verifikace a validace. Jaký je mezi těmito pojmy rozdíl?

- Verifikace je ověření, že určitou věc děláme správně. V případě modelování jde o ověření, že konkrétní implementace modelu realizuje abstraktní návrh.
- Validace je ověření, že děláme správnou věc. Jinými slovy jde o ověření, že abstraktní návrh modelu opravdu reflektuje chování reálného systému.

Validace modelu

Při validaci běžných softwarových produktů, jako je například systém pro ovládání letadla, opravdu vyžadujeme stoprocentní správnost. Validace modelu však nemůže být přímo o správnosti. Připomeňme klíčové motto modelování: Všechny modely jsou špatně, některé modely jsou užitečné. Při posuzování validity modelu tedy hodnotíme užitečnost – jak moc plní model svůj účel. Toto kritérium je částečně subjektivní a není ostré – je proto lepší mluvit o stupni validity.

V prvé řadě kontrolujeme strukturní validitu modelu, tj. kontrolujeme, že vztahy definované v modelu odpovídají vztahům v reálném systému, případně že jsou adekvátní abstrakcí. Příklady chyb: záporné hodnoty proměnných, u kterých to nedává smysl (například velikost populace), neoprávněné míchání jablek a hrušek (například převod králíků na lišky), obousměrný tok tam, kde má být jednosměrný. Příkladem poslední uvedené chyby byl ekonomický model, který předpovídal velmi optimistické výsledky, avšak detailní analýza ukázala, že to bylo způsobeno tím, že model v případě potřeby převáděl maso zpět na krávy (Sterman, 2000). Jednoduchým testem strukturní validity je otázka: Jsou všechny jednotky konzistentní? Dále kontrolujeme prediktivní validitu, tj. kontrolujeme, že chování modelu odpovídá chování systému. Tuto kontrolu můžeme provádět několika způsoby:

- Základní validita. Zkoušíme, zda chování modelu se základními parametry odpovídá očekáváním.
- Retrodikce. Pokud máme data z minulosti, spustíme model v časovém intervalu, ve kterém známe chování systému, a porovnáme data s výsledky modelu pro daný časový interval.
- Rovnováha. Pokud můžeme analyticky odvodit podmínky pro rovnováhu, vyzkoušíme, zda za těchto podmínek model opravdu vykazuje rovnovážné chování.
- Mezní hodnoty parametrů. Zkoušíme, zda se model chová rozumně, pokud nastavíme hodnoty parametrů prakticky nereálně, jinak však smysluplně, např. nastavíme porodnost (úmrtnost, pohyblivost) na nulu.

Verifikace modelu

Verifikaci můžeme zjednodušeně definovat jako kontrolu, zda model opravdu dělá, co si myslíme, že by dělat měl. V tomto případě se rozhodně snažíme o stoprocentní shodu. Verifikace modelů je však často náročnější než verifikace klasických programů, protože u výstupu modelu se občas těžko poznává, zda jde o překvapivý výsledek nebo o chybu. Pokud máme program, který má vykreslit kružnici nebo spravovat kalendář, celkem snadno dokážeme posoudit, zda funguje dobře. Pokud však máme model, který předpovídá klima na 100 let dopředu, není lehké posoudit, zda předpověď zvýšení hladiny moří o 1 metr je chyba, nebo korektní předpověď.


Základem verifikace jsou dobré modelářské praktiky: snažit se udržovat realizaci modelu co nejjednodušší, důsledně model dokumentovat, používat dobré programátorské praktiky, zveřejňovat modely pro možnost nezávislé kontroly.

Při použití modelů založených na diferenciálních rovnicích kontrolujeme, zda je výsledek numerické analýzy stabilní, tj. zda není způsoben zvolenou metodou řešení a volbou intervalu Δt . Obr. 10.1 ukazuje výsledky numerického řešení systémového modelu pomocí Eulerovy metody za použití $\Delta t = 0,001$ a $\Delta t = 0,05$. Výsledky simulace $\Delta t = 0,001$ jsou „ty správné“ – jsou stabilní, tj. přesnější simulace vede ke stejným výsledkům. Výsledky simulace pro $\Delta t = 0,05$ se však výrazně liší. Pokud použijeme $\Delta t = 0,25$, obě populace dokonce vyhynou. V reálné aplikaci by nás tyto rozdíly způsobené pouhým nastavením simulace mohli vést k zavádějícím závěrům.

Při ladění a verifikaci modelů s agenty věnujeme bedlivou pozornost jednotlivcům – pozorujeme konkrétního jednatelce a sledujeme, zda jeho chování opravdu odpovídá navrženým pravidlům. U modelů s agenty občas můžeme dostat zavádějící výsledky díky pořadí, v jakém jsou akce jednotlivých agentů vyhodnocovány, např. pokud jsou agenti rozmístěni v mřížce a vyhodnocování jejich akcí postupuje po řádcích. U většiny modelů je vhodné volit náhodné pořadí vyhodnocování.

10.3 Zobrazení chování modelu

Základní analýzou modelu je zobrazení jednoho konkrétního běhu. I zde však máme na provedení tohoto zobrazení více možností, než by se mohlo zdát.



Obr. 10.1: Výsledky simulace systémového modelu (hodnoty parametrů: $p_l = 0,006$, $u_l = 0,5$, $p_k = 1$, $u_k = 0,015$). Černé křivky odpovídají numerickému výpočtu s $\Delta t = 0,001$, šedé křivky odpovídají numerickému výpočtu s $\Delta t = 0,05$.

Vizualizace modelu

Vizuální vzhled modelu je důležitý, obzvláště pokud je účel modelu primárně pedagogický a pokud používáme modely s agenty. I když model sleduje jiné než pedagogické cíle, je kvalitní vizualizace užitečná pro verifikaci a validaci modelu a pro prezentaci a vysvětlení modelu ostatním.

Pro vizualizaci modelu obzvláště platí, že jde spíše o umění nežli o vědu. Zde zmíníme jen několik bodů, protože provedení vizualizace samozřejmě velmi závisí na konkrétním modelu. Uvedené body se vztahují především na modely s agenty.

- Může být zajímavé umožnit při vizualizaci sledovat jednotlivce, případně nabídnout zobrazení z pohledu jednotlivce.
- Numerické informace můžeme vizualizovat například pomocí velikosti objektů nebo pomocí barvy (stupně šedosti).
- Není vhodné snažit se do jedné vizualizace zahrnout všechny informace o stavu modelu.
- Může být zajímavé nabídnout více způsobů zobrazení a umožnit uživateli mezi nimi přepínat nebo si je zobrazit vedle sebe (například v modelu vody v krajině zobrazení přítomnosti povrchové vody a nasycenosti půdy).

Obr. 10.2 (horní část) ukazuje dva způsoby vizualizace modelu s králíky a trávou. V prvním způsobu je důraz kladen na králíky – ti jsou zobrazeni jako černé značky,

jejichž velikost odpovídá aktuální energii jednotlivých králíků. V druhém způsobu zobrazení je zachycena pouze tráva, přičemž barva neodpovídá přímo konkrétnímu políčku, ale váženému průměru z okolí, díky čemuž dostáváme „vyhlazený“ a přehlednější obrázek.

Časová osa

Základní krok analýzy dynamických modelů je zobrazení chování pomocí časové osy, tj. vynesení hodnoty zvolené proměnné oproti času. Na obr. 10.1 a 10.2 jsou znázorněny časové osy pro naše dva uvažované modely. I tomuto jednoduchému způsobu zobrazení stojí za to věnovat náležitou pozornost.

U modelů systémové dynamiky vynášíme do grafu přímo hodnotu použitých proměnných, u modelů s agenty většinou nezobrazujeme konkrétní proměnné použité v pravidlech (např. hodnota energie jednoho z králíků), ale musíme pro účel analýzy dodefinovat sumární proměnnou (např. celkový počet králíků). Způsob formulace sumární proměnné může být pro interpretaci výsledků velmi důležitý, a dobře se tedy zamysleme, zda opravdu zobrazujeme to, co nás nejvíce zajímá.

Může být výhodné vynášet do časové osy více proměnných současně, což nám umožňuje sledovat souvislosti v chování modelu. Zvláště v případě vynášení více proměnných věnujeme pozornost dobré volbě zobrazovaného intervalu – většinou pro každou proměnnou volíme jiný interval, aby rozsah při zobrazení byl pro všechny proměnné podobný, viz obr. 10.2 dole vlevo: levá osa grafu odpovídá počtu králíků, pravá osa průměrnému množství trávy. Pokud mají dvě proměnné stejnou jednotku, může však být smysluplné zobrazovat je vzhledem ke stejnému intervalu.

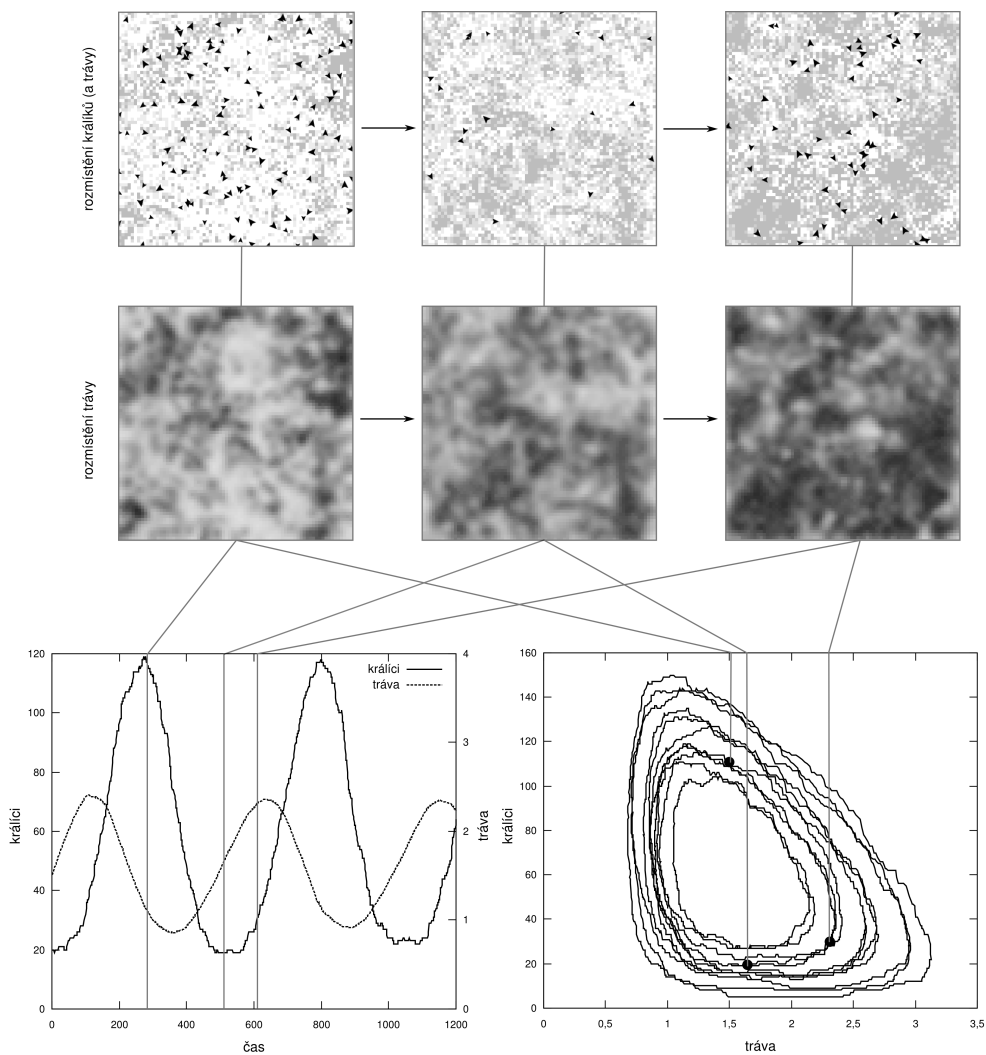
Délka zobrazeného časového intervalu je také velmi důležitá, vždy vyzkoušíme několik různě dlouhých časových intervalů, abychom zjistili, který je nejvíce vypovídající. Pokud máme k dispozici reálná data, je užitečné vynést na časovou osu pro srovnání reálná a simulovaná data.

Stavový prostor


Stav každého modelu je vyjádřen vektorem proměnných délky n , a to i pro modely s agenty, u kterých je tento vektor proměnných pouze hodně dlouhý — například model s trávou a králíky obsahuje aktuální polohu a energii všech králíků a aktuální množství trávy na všech políčkách. Stav modelu si tedy můžeme představit jako bod v n -rozměrném prostoru a chování modelu (simulaci) jako cestu tímto n -rozměrným prostorem. Pokud je systém deterministický, chování modelu odpovídá neprotínající se křivce nebo padá do smyčky.

Protože zobrazovat umíme jednoduše pouze v dvojrozměrném prostoru, můžeme stavový prostor přímočaře zobrazit, pouze pokud $n = 2$. To je případ našeho systémového modelu králík–liška, jehož zobrazení je na obr. 10.3.

Ve většině případů však je $n > 2$. V takové případě stále může být užitečné zachytit průmět stavového prostoru do roviny, čehož dosáhneme zobrazením vybraných sumárních proměnných proti sobě. Obr. 10.2 (dole vpravo) ukazuje průmět



Obr. 10.2: ABM model: tráva a králíci. V horní části jsou zachyceny tři stavy modelu, každý z nich je zachycen dvěma různými způsoby. Dolní část zachycuje vývoj modelu v grafech: časová osa a stavový prostor. V grafech je znázorněna poloha tří stavů uvedených v horní části obrázku.



Obr. 10.3: Výsledky simulace systémového modelu (hodnoty parametrů: $p_l = 0,006$, $u_l = 0,5$, $p_k = 1$, $u_k = 0,015$). Křivky vyznačují chování modelu pro různé iniciální hodnoty proměnných. Šipky znázorňují směr a velikost změny (derivace) v daném bodě. Stavový prostor je rozdělen na 4 kvadranty: v kvadrantu I roste populace kořisti a klesá populace lovce, v kvadrantu II obě populace rostou, v kvadrantu III klesá populace kořisti a roste populace lovce, v kvadrantu IV klesají velikosti obou populací. Tečka značí rovnovážný stav.

stavového prostoru pro ABM model. Když porovnáme obě zobrazení stavových prostorů, vidíme, že základní dynamika systémového modelu i ABM modelu jsou velmi podobné.

V zobrazení můžeme kromě dráhy, která odpovídá konkrétnímu běhu modelu, zobrazit také šipky, jež odpovídají směru vývoje modelu v jednotlivých bodech stavového prostoru (resp. průmětu). Obr. 10.1 zobrazuje tyto šipky pro systémový model, pro který byl směr a velikost šipek vypočítán přesně analyticky podle definice modelu – diferenciální rovnice tvořící model udávají právě tuto informaci. Pokud zobrazujeme průmět stavového prostoru, získáme šipky pomocí zprůměrování velkého množství běhů simulace. Tím se dostáváme od technik k zobrazení jednoho běhu modelu k technikám ke zpracování více běhů.

10.4 Analýza citlivosti

Pro důslednou analýzu modelu nestačí pracovat s jedním během, ale musíme provést větší množství běhů a ty zpracovat. Provádíme především analýzu citlivosti, jejímž cílem je určit vliv parametrů na chování modelu, konkrétně pak:

1. Chceme zjistit, jak moc hodnoty, které jsme odhadli, ovlivňují chování modelu, a tedy jak moc obdržené chování závisí na správnosti našeho odhadu.
2. Chceme zjistit, které parametry mají vysoký a které nízký vliv na chování modelu.

Základní princip analýzy citlivosti je jednoduchý: měníme hodnoty parametrů a sledujeme, jak se mění chování modelu. Věnujeme pozornost základnímu typu vykazovaného chování (oscilace, stabilita, kolaps), ale také numerickým hodnotám. Analýza citlivosti je pochopitelně tím náročnější, čím více parametrů model obsahuje. To je jeden z důvodů, proč je dobré modely udržovat co nejjednodušší, a je to také jedna z nevýhod modelů s agenty – sice dobře vypadají, ale bývá náročné je dobře analyzovat, protože často mívají velké množství parametrů.

Analýza citlivosti je jedním ze základních kroků simulace, takže většina nástrojů pro modelování a simulaci obsahuje podporu pro tuto analýzu. Podpora většinou umožňuje jednoduše spustit simulaci pro velké množství hodnot parametrů a vyhodnotit výsledky běhů.


Vizuální analýza

Základní způsob zobrazení výsledků je opět pomocí časové osy, případně pomocí zobrazení stavového prostoru. Obr. 10.4 ukazuje výsledky analýzy citlivosti pro systémový model vzhledem k parametru u_l (úmrtnost lišek). Z obrázků dobře vidíme vliv tohoto parametru na chování modelu. Základní mód chování (oscilace) se nemění, ovšem délka oscilací na parametru u_l výrazně závisí. Parametr u_l ovlivňuje minimální a maximální velikost populace lišek i minimální velikost populace králíků. Pouze maximální velikost populace králíků je na parametru u_l nezávislá. Vyšší hodnoty parametru u_l vedou ke stabilnějšímu chování (menší výkyvy) – to je proto, že vyšší hodnota parametru posiluje negativní zpětnou vazbu, která model udržuje v rovnováze.


V případě modelů využívajících náhodu (resp. generátor náhodných čísel) ověřujeme také, jak moc závisí chování modelu na náhodě. Obr. 10.5 ukazuje výsledek takové analýzy pro ABM model – vidíme, že v tomto případě se jednotlivé běhy postupně mírně rozbíhají, celkově je však chování modelu stabilní. Tento typ analýzy se dá přesněji formalizovat pomocí statistických metod (např. určování intervalů spolehlivosti), tyto metody jsou však nad rámec této knihy.

Numerická analýza


Závislost chování modelu na parametrech můžeme studovat i přesněji než jen náhledem na časové osy. Pro přesnější analýzu musíme jasně formulovat chování modelu,



Obr. 10.4: Výsledky analýzy citlivosti systémového modelu (hodnoty parametrů: $p_l = 0,006$, $u_l = 0,5$, $p_k = 1$, $u_k = 0,015$), jediná změna: hodnota parametru u_l .



Obr. 10.5: ABM model: souhrnné výsledky pro 20 běhů se stejnými hodnotami parametrů, pouze s rozdílně inicializovaným generátorem náhodných čísel. Prostřední křivka znázorňuje průměr ze všech běhů, krajní křivky maximum a minimum.



Obr. 10.6: ABM model: pravděpodobnost vyhynutí populace králíků během prvních 2000 časových jednotek v závislosti na hodnotě parametru udávající limit energie, při kterém se králíci množí.

kteřé nás zajímá, a vyjádřit toto chování numericky pomocí výstupní proměnné. Simulaci poté spustíme s různými hodnotami parametru a měříme hodnotu výstupní proměnné. Pro modely využívající náhodu spustíme experiment vícekrát a hodnotu zprůměrujeme. Výsledky zobrazíme pomocí bodového grafu, případně analyzujeme pomocí statistických metod (např. regrese).

Obr. 10.6 ukazuje příklad tohoto typu analýzy pro ABM model. V tomto případě výstupní proměnná nese informaci o tom, zda došlo k vyhynutí populace králíků během prvních 2000 kroků simulace, a studujeme závislost této proměnné na jednom z parametrů modelu (limitní energie). V grafu je vynesena pravděpodobnost vyhynutí, která byla získána zprůměrováním 40 běhů. Zmiňme další příklady tohoto typu analýzy, které bychom mohli s našimi modely provádět: Jak ovlivňuje hodnota parametrů délku a amplitudu oscilací? Při jakých hodnotách parametrů je průměrná velikost populace králíků největší?

Při těchto analýzách se zaměříme na hledání fázového přechodu v chování modelu. Fázový přechod znamená, že model vykazuje prudkou změnu chování vzhledem ke zvolenému parametru. Náš příklad (obr. 10.6) ukazuje ještě relativně pozvolný přechod mezi dvěma módy chování (přežijí, nepřežijí).

Jednoduchým příkladem prudkého fázového přechodu je abstraktní model požáru lesa (Wilensky, 1998). Les je představován pravidelnou čtvercovou mřížkou, na které každé pole je buď volné, nebo obsahuje strom. Na jedné straně mřížky zahájíme požár (zapálíme všechny stromy). Požár se šíří ze stromu na strom, a to pouze mezi bezprostředně sousedními poličky (nemůže přeskočit volné pole). Jaká je pravděpodobnost, že požár dosáhne až na druhou stranu mřížky? Model vykazuje fázový

přechod v závislosti na hustotě stromů. Do hustoty 60 % je pravděpodobnost „prohoření“ velmi malá, při hustotě nad 60 % velmi velká, a k překlopení mezi těmito dvěma režimy dochází velmi rychle.

Určení fázových přechodů v chování modelu je velmi důležité pro dobré pochopení modelu a modelovaného systému. Parametry, vůči kterým model vykazuje fázový přechod, představují „pákové body“, u nichž malá změna hodnoty může výrazně změnit chování (více o pákových bodech v kapitole 17). Fázový přechod je důležitý koncept také proto, že jde často o neintuitivní prvek v chování – lidé intuitivně očekávají spíše lineární změny v chování, nikoliv skokové.

10.5 Experimenty s modelem

Jakmile máme důvěru v model a rozumíme jeho chování a vlivu parametrů, můžeme se pustit do experimentů typu: „Co se stane, když...?“ Tyto experimenty spočívají v provádění změn v modelu, sledování jejich dopadu a případném vzájemném porovnávání.

Cíle experimentů

Proč provádíme experimenty s modelem? Mezi nejčastější důvody patří:

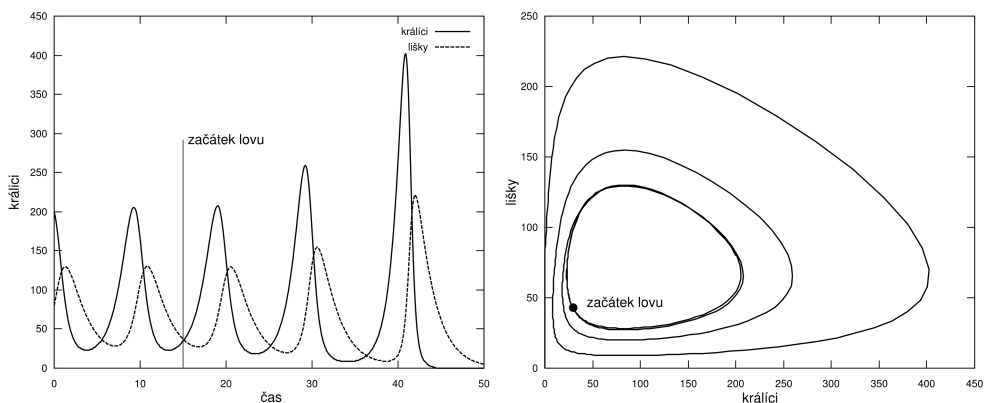
- Provéřit naše chápání modelu (systému).
- Vyhodnotit různé způsoby práce se systémem a vybrat ten nejefektivnější.
- Vyzkoušet prostřednictvím modelu reakci systému na experimenty, které nelze provést v realitě (např. z praktických či etických důvodů).
- Predikce výsledků experimentů, z nichž pak vybrané posléze ověřujeme v realitě (tento cíl se používá například v systémové biologii, viz část 16.3).
- Porovnat různé hypotézy ohledně fungování systému.

Typy experimentů

Experimenty většinou spočívají v provedení strukturní změny v modelu, např. přidání nového toku v systémovém modelu či nového pravidla pro agenty. Tuto změnu můžeme provést „staticky“ a spustit rovnou pozměněný model. Často je však lepší provést změnu „dynamicky“, za běhu modelu, protože pak můžeme porovnat původní chování modelu s chováním po změně.

Úpravy modelu samozřejmě závisejí na konkrétním modelu, obecně můžeme pouze charakterizovat způsob provedení změn. Většinou využijeme jedno ze tří možných provedení:

- Skoková změna: od určitého okamžiku dojde k vnější změně, např. zahájíme pravidelný výlov králíků, na most vjede těžké auto.
- Pravidelný impulz: v pravidelných intervalech dochází k vnějším impulzům, např. k výlovu králíků dochází jednou za dva roky, po mostě synchronizovaně pochoduje jednotka.



Obr. 10.7: Systémový model s lovem (skoková změna). Hodnoty parametrů: $p_l = 0,006$, $u_l = 0,5$, $p_k = 1$, $u_k = 0,015$, v čase 15 začíná konstantní výlov tří králíků za jednu časovou jednotku.

- Zátěžová zkouška: od určitého okamžiku dochází k stále narůstající změně – tento typ experimentu většinou vede ke kolapsu, zajímá nás, kdy a jak ke kolapsu dojde, např. zahájíme stále se zintenzivňující výlov králíků, na most nakládáme větší a větší zátěž.

Obr. 10.7 ukazuje příklad experimentu se systémovým modelem. Experiment spočívá ve skokové změně – v čase 15 začíná konstantní výlov tří králíků za jednu časovou jednotku. Vidíme, že tato změna vyvádí systém z pravidelných oscilací, změna nejprve vede k zvyšující se amplitudě oscilací. Z krátkodobého hlediska tedy výlov králíků vede neintuitivně k výraznému nárůstu počtu králíků. Brzy však dochází ke kolapsu a k vymření obou populací.

Souvislosti: Zpracování dat z analýzy neprovádíme „na koleně“, ale využíváme vhodné externí programy, které jednoduše umožňují zpracování základních statistik a jejich vizualizaci pomocí grafů. Náměty na konkrétní nástroje jsou uvedeny v příloze C.

10.6 Shrnutí

- Důkladné analýzy modelu tvoří klíčovou součást procesu modelování a simulace.
- Model nemůže být nikdy zcela validní, protože model je z principu vždy špatně. Otázka není, jestli je model správně, ale jestli je užitečný. Validita je tedy mírně subjektivní.

- Verifikace (ověření, že model správně dělá to, co má) je naopak objektivní a velmi důležitá, protože není lehké poznat, co je chyba modelu a co překvapivý korektní výsledek.
- Základním typem analýzy je zkoumání jednoho běhu modelu (vizualizace, zobrazení časové osy, průmět stavového prostoru). Tato analýza nám pomáhá pořádně porozumět chování modelu (a potažmo modelovaného systému).
- Pomocí analýzy citlivosti zkoumáme vliv jednotlivých parametrů na chování modelu. Citlivost zkoumáme jak vizuálně, tak numericky.
- Experimenty s modelem spočívají ve zkoumání otázky „Co se stane, když. . .?“ Pomocí těchto experimentů porovnáváme vliv různých zásahů do modelu (systému).

Část III

Případové studie

V třetí části knihy se podíváme na konkrétní aplikace. V rámci popsaných aplikací se většinou kombinuje několik technik popsaných v druhé části textu, případně se tyto techniky hlouběji rozvíjejí. Kapitoly v této části jsou vyloženy inspiračně a ilustračně. Cílem není úplný a systematický výklad o dílčích tématech, ale ilustrace použití modelů na známých a zajímavých příkladech.

Kapitola 11 se zabývá modelováním epidemií a jejím účelem je mimo jiné zopakování probraných technik (matematické modelování, modelování s agenty, modelování s využitím komplexních sítí) a srovnání těchto technik na jednom příkladě.

Kapitola 12 popisuje modely, které ilustrují principy života. Nevěnujeme se modelování konkrétních organismů, ale obecných principů, na nichž život funguje. Rozhodně nejde o systematický biologický výklad, ale pouze o ukázky zajímavých modelů. V kapitole jsou využity buněčné automaty, modely s agenty, teorie her i systémové modelování.

Kapitola 13 popisuje několik zajímavých příkladů z oblasti modelování sociálních a ekonomických systémů. Jsou použity především modely s agenty, rozšířené například o učení s pomocí klasifikačního systému.

Kapitola 14 se zabývá výhodností spolupráce a altruismu v soutěživém prostředí. Základní použitý model je hra Dilema vězně, která se dále rozšiřuje a kombinuje s různými modelovacími technikami (agenti, genetické algoritmy, buněčné automaty).

Kapitola 15 popisuje jeden konkrétní rozsáhlý systémový model – model World3 zkoumající interakci rostoucí ekonomiky a limitů planety. Na tomto příkladě ilustrujeme i obecnější souvislosti modelování.

Kapitola 16 uvádí příklady rozsáhlých aplikací modelování (počasí a klima, doprava, systémová biologie). V této kapitole již nerozebíráme detailně konkrétní modely, ale zmiňujeme pouze hlavní principy a způsoby použití modelů.

Kapitola 17 už je vyložena netechnická a zabývá se tím, jak použít v běžném životě principy, které nás modelování učí.

11 Epidemie

S: Tak jak se daří?

M: Ale, už třetí den ležím, zase mě dostala chřipka. Jak tak ležím, tak jsem přemýšlel. Čím to je, že mají různé nemoci tak různý průběh epidemie? Taková epidemie chřipky propuká pravidelně každý rok, ale není úplně katastrofální, kdežto mor míval nepravidelné silné epidemie, které se rychle šířily, a takový AIDS se šíří čím dál víc, ale relativně pomalu.

S: Tak především záleží na infekčnosti dané choroby. V mnoha případech existuje práh davové imunity, a pokud je infekčnost pod tímto prahem, tak se choroba nešíří, ale když překročí práh, nastává epidemie. . .

M: Moment, ty jsi expert na epidemiologii? To jsem tedy netušil, že se vyznáš i v medicíně.

S: Žádný expert nejsem. Dynamika epidemií je však do značné míry nezávislá na vlastním průběhu choroby, a tedy na medicínských znalostech. Abys mohl epidemii věrohodně namodelovat, stačí znát pár základních parametrů, jako je infekčnost, inkubační doba či úmrtnost. Pro pacienta je samozřejmě důležité, co přesně nemoc dělá s tělem, z pohledu dynamiky epidemie to ale zásadní není. Dokonce můžeš použít velmi podobné modely nejen pro šíření nemocí, ale i pro šíření naprosto jiných druhů epidemií, jako jsou počítačové viry na internetu nebo módní trendy šířící se v sociální síti.

M: Počkej, zůstaň ještě chvíli u těch nemocí. Jak jsem ti říkal o přemnožených králících v Austrálii, tak jeden z pokusů, pomocí kterých se pokoušeli králíky zdecimovat, byla uměle vyvolaná epidemie myxomatózy. Mělo to docela zajímavý průběh – nejdříve byla úmrtnost králíků vysoká, ale pak se rozšířila v populaci odolnost vůči myxomatóze a velikost populace králíků se nakonec příliš nesnížila. To by mohlo být zajímavé ilustrovat na modelu, ne?

S: Určitě. Mimochodem to je docela netradiční případ, protože většinou se lidé snaží šíření epidemie spíše zabránit, tedy hledat vhodné způsoby imunizace. S využitím modelů se tedy hledají odpovědi na otázky týkající se vhodných preventivních opatření nebo cílení imunizace.

11.1 Základní koncepty

Hlavním cílem této kapitoly je naznačit základní přístup k modelování epidemií a ilustrovat, jak lze použít modelovací techniky uvedené v druhé části knihy.

Modelování epidemií

Modelování epidemií je jednou z nejvíce rozšířených a hojně používaných oblastí modelování komplexních systémů. Epidemie se dají dobře a věrohodně modelovat díky tomu, že pro zkoumání dynamiky epidemie nám stačí dívat se na nemoc velmi abstraktně. Dokonce tak abstraktně, že pomoci velmi podobných modelů můžeme věrohodně zachytit velmi odlišné typy epidemií – chřipka, AIDS, mor, nemoc šílených krav, ale také šíření počítačových virů, drbů, postojů, nových technologií a módních trendů. Pro jednoduchost budeme v kapitole používat terminologii biologických nemocí, většinu zmíněných modelů však lze jednoduše přeformulovat do ostatních interpretací.

Modelování epidemií je téma, které se v současnosti hojně zkoumá. Důvodem pro intenzivní zkoumání je i dobrá finanční podpora – epidemie jsou totiž citlivým politickým problémem, a to ať už jde o pomalé a těžko zadržitelné šíření AIDS, riziko rychlého rozšíření nové nemoci typu SARS nebo hrozbu biologického teroristického útoku.

Studované otázky

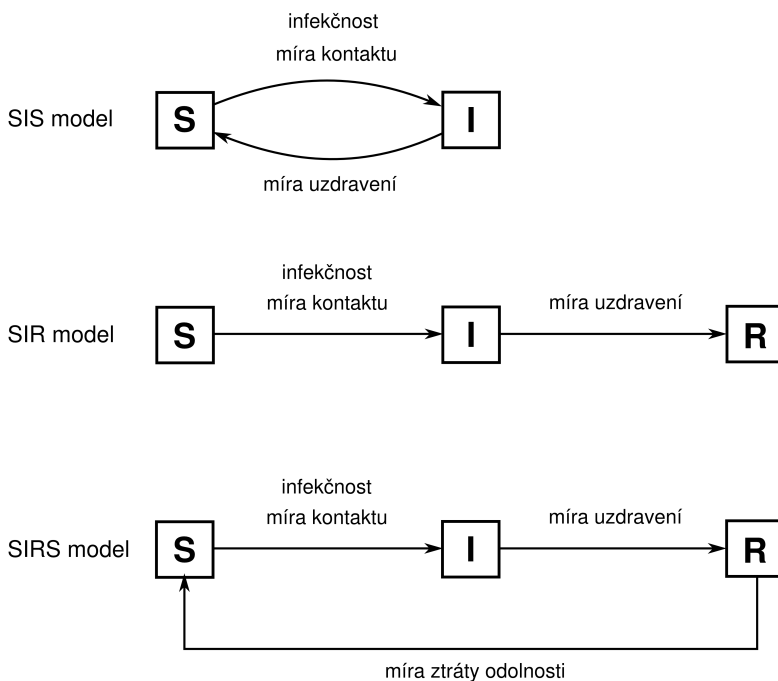
Mezi typické otázky, na které hledáme odpověď pomocí modelů epidemií, patří:

- Proč mají různé epidemie různou dynamiku (stabilní stav, mírné oscilace, nepravidelné velké epidemie)?
- Jaká je minimální velikost populace potřebná k tomu, aby se v ní nemoc udržela dlouhodobě?
- Existuje ostrá mez infekčnosti, jejíž překročení znamená vypuknutí epidemie?
- Jak ovlivňuje struktura kontaktů mezi jedinci dynamiku epidemie?
- Jaká jsou vhodná preventivní opatření proti vzniku epidemie?
- Jak cílit imunizaci, abychom co nejlépe zabránili šíření epidemie?

Základní typy modelů

Ať už modelujeme epidemie jakoukoli modelovací technikou, základní abstraktní struktura modelů je vždy podobná: populaci rozdělíme do několika tříd podle zdravotního stavu a popisujeme přechody mezi těmito stavy. Obr. 11.1 znázorňuje tři základní typy modelů epidemií. Názvy typů modelů ponecháváme podle anglických zkratk, protože jde o standardní a rozšířenou notaci.

SIS (Susceptible – Ill – Susceptible) SIS je nejjednodušší model, v němž rozlišujeme pouze jedince, kteří jsou či nejsou nemocní. Jedinec, který se uzdraví, se stává opět náchylným k nemoci.



Obr. 11.1: Schematické znázornění tří základních modelů epidemií, význam stavů: S = susceptible = zdravý a náchylný k nemoci, I = ill (infective) = nemocný a infekční, R = recovered, removed, resistant = uzdravený, mrtvý nebo odolný.

SIR (Susceptible – Ill – Recovered/Removed/Resistant) V tomto případě může jedinec onemocnět maximálně jedenkrát, po nemoci se nestává znovu náchylným. Interpretace třetího stavu může být různá – jedinec může být mrtvý, nebo může získat trvalou imunitu proti nemoci. Dotyčnému jedinci dozajista záleží na rozdílu mezi stavem „mrtvý“ a stavem „zdravý a imunní“, z pohledu průběhu epidemie však vycházejí tyto dva stavy téměř nastejno a nemusíme mezi nimi rozlišovat.

SIRS (Susceptible – Ill – Resistant – Susceptible) V tomto případě jedinec po vyléčení získává odolnost vůči nemoci, odolnost však vydrží jen určitý čas a pak se jedinec opět stává náchylným.

Tyto modely mají společné základní principy pro přechod mezi stavy. Přechod ze stavu náchylný do stavu nemocný závisí na infekčnosti nemoci a na míře kontaktu náchylných jedinců s infekčními. Přechod ze stavu nemocný do stavu zdravý závisí na délce nemoci, resp. míře uzdravení, jež udává očekávaný podíl jedinců, kteří se uzdraví za jednotku času (tato míra se používá, protože v matematických modelech se s ní pracuje jednodušeji než s délkou nemoci). Podobně funguje i ztráta odolnosti.

Souvislosti: Popis základních typů modelů epidemií lze najít v mnoha zdrojích. Ellner a Guckenheimer (2006) věnují kapitulu matematickým modelům epidemií a rozebírají mimo jiné i analytické metody studia modelu. Deaton a Winebrake (1997) popisují jednoduchý systémový model epidemie SIRS a jeho analýzu. Krebs (2001) zmiňuje matematické modely epidemií v kontextu učebnice ekologie. Sterman (2000) popisuje systémové modely, přičemž se zabývá nejen epidemiemi biologických nemocí, ale i šířením nových produktů a podobnými „sociálními“ epidemiemi. O studiu epidemií na komplexních sítích lze najít několik příspěvků ve sborníku od editorů Bornholdta a Schustera (2003). Gladwell (2000) se zabývá sociálními epidemiemi v populárně psaném stylu (bez explicitního použití modelů).

11.2 Jednoduché modely SIR epidemie

Nyní se podíváme detailně na model SIR, který je asi nejčastěji studovaný. Ukážeme, jak realizovat tento model pomocí různých modelovacích technik. Jde o úplně základní jednoduché modely, v další části kapitoly pak rozebereme, jak se dají tyto modely rozšířit.

Stav R pro naše ukázky interpretujeme jako „mrtvý“ (removed). Modely tedy rozlišují tři stavy jedinců (zdravý, infekční, mrtvý) a mají dva základní parametry (infekčnost a míra úmrtnosti).


Matematický model

V matematickém modelu vyjadřujeme pouze celkové počty zdravých (proměnná S), nemocných (proměnná I) a mrtvých (proměnná R). Předpokládáme homogenní prostředí, což znamená, že míra kontaktu mezi zdravými a nemocnými je úměrná pouze velikosti těchto dvou populací (tj. součinu $S \cdot I$). Na základě těchto předpokladů můžeme model vyjádřit následujícími diferenciálními rovnicemi (β je infekčnost, γ je úmrtnost):

$$\begin{aligned} dS/dt &= -\beta SI \\ dI/dt &= \beta SI - \gamma I \\ dR/dt &= \gamma I \end{aligned}$$

Základní otázkou při zkoumání epidemií je, zda epidemie vůbec vypukne, tj. zda se nemoc výrazně rozšíří v populaci. V tomto jednoduchém modelu lze situaci jednoduše analyzovat. Klíčovou hodnotou je poměr $\beta S/\gamma$. Pokud je $\beta S/\gamma < 1$, bude se počet nemocných pouze snižovat a k epidemii nedojde, pokud je $\beta S/\gamma > 1$, bude se počet nemocných alespoň nějaký čas zvyšovat, tj. k epidemii dojde.

Obr. 11.2 ukazuje typický výsledek simulace modelu. Na začátku simulace je pouze několik nemocných jedinců, všichni ostatní jsou náchylní. Nemoc se začne rychle šířit, počet infekčních rychle stoupá. Jak však ubývá náchylných jedinců, šíření nemoci se postupně zastavuje a systém se dostává do stabilního stavu bez infekčních



Obr. 11.2: Výsledky simulace jednoduchého matematického modelu epidemie SIR.

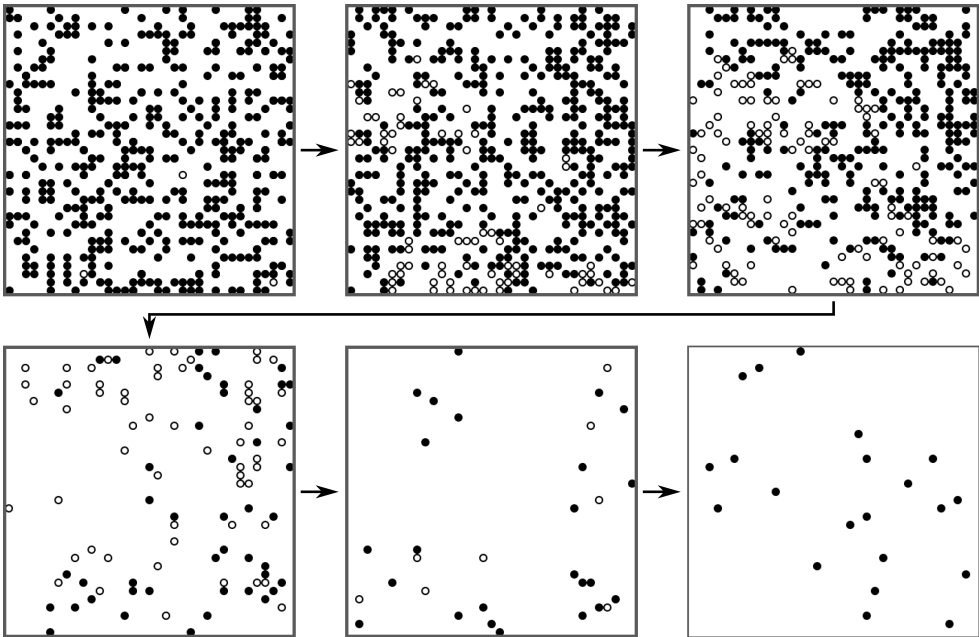
jedinců. Počet odolných jedinců sleduje křivku logistického růstu, který jsme probírali v kapitole 6.

Souvislosti: Uvedený model jako první formulovali Kermack a McKendrick (1927), podle kterých se model občas nazývá. Podrobnější popis matematických modelů epidemií uvádí například Ellner, Guckenheimer (2006).

Model s agenty v prostoru

Při modelování epidemií pomocí agentů se můžeme vyhnout předpokladu homogeneity, který není příliš realistický, a můžeme zachytit vztahy mezi jednotlivci věrněji. Pro účely jednoduchého modelu však zůstaneme blízko homogenního mixování – budeme používat pouze náhodný pohyb po dvourozměrné mřížce. Pravidla základního modelu jsou následující:

- Agenti se pohybují náhodně, v každém tahu se pohnou o jedno pole.
- Agent může být zdravý nebo infekční.
- Pokud se zdravý agent vyskytuje vedle infekčního, může se stát infekčním (s pravděpodobností odpovídající infekčnosti).
- Infekční agent může zemřít (s pravděpodobností odpovídající míře úmrtnosti). Mrtví agenti jsou odstraněni z mřížky.



Obr. 11.3: Epidemie SIR, model s agenty: plná kolečka představují zdravé agenty, prázdná kolečka agenty infikované.


Obr. 11.3 ukazuje příklad vývoje modelu. Celkové počty agentů podle jednotlivých typů (náchylný, infekční, mrtvý) jsou podobné jako v případě výsledků matematického modelu na obr. 11.2. V tomto případě samozřejmě výsledný graf není „hladký“, protože výsledky simulace záleží na náhodě.

Model na síti

Agenty nemusíme umísťovat pouze do prostoru, můžeme je umístit také do uzlů sítě, která reprezentuje kontakty mezi agenty (např. sociální síť). Jednoduchý příklad takového modelu je následující:

- Vygenerujeme síť reprezentující vztahy mezi agenty (např. náhodnou síť nebo model bezškálovité sítě).
- Epidemie se šíří po hranách, tj. pokud má zdravý jedinec (uzel) infekčního souseda, pak se s určitou pravděpodobností stane infekčním.
- Infekční jedinec (uzel) s pravděpodobností úměrnou míře úmrtnosti zemře a je odstraněn (spolu se všemi svými hranami).

Obr. 11.4 ilustruje vývoj na bezškálovité síti. I na tomto malém příkladě je vidět vysoký význam center (uzlů s vysokým stupněm) pro šíření nemoci. Díky centrům



Obr. 11.4: Epidemie SIR, model na bezškálovité síti: plná kolečka představují zdravé agenty, prázdná kolečka infikované agenty, šedá kolečka mrtvé agenty.

se epidemie může rozšířit i s velmi malou infekčností. Tento model tak, na rozdíl od matematického modelu s homogenním prostředím, nevykazuje ostrou mez infekčnosti pro šíření epidemie.

Souvislosti: V příloze D jsou rozepsány náměty na praktická cvičení s modely epidemií.

11.3 Rozšíření základních modelů

Uvedené jednoduché modely jsou vhodné pro ilustraci základních principů modelování epidemií, pro zodpovězení otázek zmíněných na začátku kapitoly však nedostačují. Abychom mohli na tyto otázky odpovědět, musíme modely dále rozšířit. Možných rozšíření je hodně a při modelování musíme mít stále na paměti, že cílem je vždy modelovat problém, a nikoliv systém. Rozšíření, která do modelu zahrnujeme, tedy vždy musí odpovídat otázce, kterou chceme pomocí modelu odpovědět. V této části již neuvádíme konkrétní modely, ale zmiňujeme pouze základní přístupy k modelování.

Kontakty v rámci populace

Jedním ze základních prvků všech modelů epidemií je přenos nemoci kontaktem mezi infekčním a zdravým jedincem. Způsob, jakým tyto kontakty v modelu zachytíme, má tedy výrazný vliv na chování modelu. Základní možnosti modelování kontaktů jsou následující (seřazeno přibližně podle složitosti modelování):

- Homogenní populace, ve které předpokládáme, že míra kontaktu je úměrná pouze velikosti populace zdravých a nemocných.
- Subpopulace, v rámci kterých předpokládáme homogenní kontakty, mezi subpopulacemi pak je výrazně nižší stupeň kontaktů. Subpopulace mohou představovat například sociální skupiny nebo fyzicky oddělené populace (ostrovy, města).
- Abstraktní model společenského života. Každý agent denně absolvuje trasu mezi zadanými místy (např. domov, práce, obchod) a ke kontaktu dochází s jedinci vyskytujícími se ve stejný čas na stejném místě (např. spolubydlíci, spolupracovníci).
- Sociální síť. Kontakty zachytíme pomocí statické komplexní sítě. Kontakty mohou mít různou váhu, a tedy odpovídající různou pravděpodobnost šíření infekce.
- Konkrétní model společenského života zpracovaný na základě geografických a demografických dat, pomocí kterého se snažíme o co nejvěrnější zachycení chování reálné populace.

Homogenní populace a subpopulace můžeme zachytit pomocí matematických a systémových modelů, na další rozšíření již potřebujeme modely s agenty a modely sítí.

Kromě studia obecných otázek o epidemiích mohou být tato rozšíření užitečná pro studium otázek, které souvisí specificky s kontakty v rámci populace. Jak se projevuje na dynamiku epidemií „zkracování vzdáleností“ díky rychlejšímu a snadnějšímu cestování? Jaký efekt mají na dynamiku epidemií současné civilizační trendy (např. nárůst počtu zběžných kontaktů, stěhování do měst)? Jak souvisí geografie s epidemiemi? V Japonsku proběhlo mezi 11. a 19. stoletím 36 epidemií spalniček, nikdy se však spalničky neudržely dlouhodobě, a to i přesto, že populace Japonska byla dostatečně velká na to, aby se v ní nemoc dlouhodobě udržela. Může to být způsobeno geografickou povahou Japonska (úzký dlouhý ostrov)?

Heterogenita populace

V základních modelech považujeme všechny jedince za identické a rozlišujeme mezi nimi pouze podle zdravotního stavu. Může mít význam uvažovat podrobnější rozlišení jedinců, smysluplné jsou především následující kategorie:

- Věk. Jedinec může mít minimální či maximální věk, kdy může onemocnět, případně se může náchylnost k nemoci s věkem měnit.

- Imunita (odolnost proti nemoci), případně schopnost šířit nemoc. Schopnost šířit nemoc je relevantní spíše pro alternativní interpretace epidemií, jako je šíření drbů či nových technologií.
- Množství a charakter kontaktů.

V matematických a systémových modelech můžeme tato rozšíření zachytit jen omezeně, v modelování s agenty je naopak pro jejich vyjádření přirozené.

Populační dynamika a čas

Zahrnutí populační dynamiky (rození a umírání jedinců) je důležité především pro studium nemocí, u kterých jedinci získávají po překonání nemoci trvalou imunitu proti nemoci (tj. SIR model). Pokud neuvažujeme populační dynamiku, pak nemoc musí v každém případě odeznít pro nedostatek dalších obětí. Díky rození dětí však stále přibývají nové potenciální oběti a epidemie tak může vykazovat například oscilující chování.

Časové hledisko můžeme zohlednit také vzhledem k ročním obdobím, například infekčnost chřipky je větší v zimě než v létě.

Zásahy proti epidemii

Epidemie samozřejmě chceme nejen pochopit, ale i ovlivňovat. Pokud jde o epidemii nemoci, snažíme se ji ztlumit. V případech, jako je šíření nových produktů či myšlenek, se můžeme naopak snažit epidemii rozšířit.

Základní způsob zásahu proti epidemii je snížení infekčnosti, např. pomocí vakcinace nebo fyzických bariér (rouška, kondom). Můžeme studovat různé způsoby vakcinace: preventivní či po propuknutí nemoci, vakcinace plošná, náhodná či cílená. Může být cílená na vybranou subpopulaci nebo pomocí sledování kontaktů nemocných. V případě šíření nového produktu může jít o zvýšení „infekčnosti“ pomocí reklamy. Další způsoby zásahu jsou snížení množství kontaktů (např. karanténa, izolace nemocných) nebo vybití nemocných, případně i zdravých jedinců podle určitého klíče (tento způsob se v současné době používá pouze u nemocí zvířat).

Modelování zásahů je většinou poměrně přímočaré (např. změna parametru infekčnost).

Mutace nemoci

Mnohé nemoci se vyvíjejí a v průběhu času se objevují jejich nové varianty, které mohou překonávat dříve získanou imunitu. Typickým příkladem je například chřipka. Pouhé rozlišení mezi stavem „náchylný“ a „odolný“ tak nemusí být dostačující.

Často dochází dokonce ke koevoluci mezi populací a virem, v případě lidské populace jde spíše o koevoluci mezi léky a virem. Tento aspekt nemocí ovlivňuje nejen charakter epidemií, ale má i důležité dopady na evoluční vývoj – koevoluce mezi populací a virem pomáhá udržovat diverzitu v rámci populace a někteří výzkumníci

dokonce zastávají názor, že hlavní důvod, proč se vyvinulo sexuální rozmnožování, je obrana proti virům (Hamilton et al., 1990).

Jednoduché mutace, například jednotlivé „sezónní“ varianty chřipky, můžeme vyjádřit i v matematickém modelu nebo v jednoduchém modelu s agenty. Ke studování složitějších koevolučních aspektů vývoje nemocí pak využijeme například genetické algoritmy.

11.4 Příklady studií a nástrojů

Pro představu o tom, jak vypadají realistické studie epidemií s využitím modelů, zde stručně popíšeme dva konkrétní příklady.

Model epidemie neštovic ve dvou městech

Příklad středně složitého modelu je model neštovic (Epstein, 2006). Jde o model založený na agentech, který je výrazně komplikovanější než výše zmíněný jednoduchý model, nevyužívá však reálná data o pohybu agentů, tj. jde stále o čistě abstraktní umělý svět. Hlavní motivací studie je hledání vhodných způsobů zásahu proti bioteroristickému útoku – práce vznikla v době po teroristických útocích v září 2001, kdy navíc probíhala aféra s antraxovými obálkami. Práce se zaměřuje konkrétně na neštovice. Plošná vakcinace proti neštovicím skončila v USA v roce 1972, kdy byla tato nemoc plošně vymýcena. To ovšem znamená, že značná část současné populace je proti případnému znovurozšíření nemoci náchylná.

Základní struktura modelu a kontaktů mezi agenty je následující:

- Model rozlišuje několik typů míst: domácnosti, pracoviště, školy, nemocnice, hřbitov. Ke kontaktu dochází pouze v rámci těchto míst.
- V modelu jsou dvě samostatná města o stejné velikosti a struktuře.
- Dospělí agenti se pohybují mezi domácností a pracovištěm, děti mezi domácností a školou. Část dospělých pracuje v nemocnici, malá část dospělých pracuje v druhém městě.

Model je kalibrován na základě historických dat o šíření neštovic. Konkrétní nastavení parametrů nemoci odráží co nejvěrněji skutečnost: během prvních 12 dnů je jedinec infikovaný, ale nemoc se neprojevuje a nepřenáší, další tři dny se nemoc projevuje a jedinec je infekční, pak následuje osmidenní období silných projevů nemoci a silné infekčnosti, poté se jedinec buď uzdraví, nebo zemře.

Pomocí tohoto modelu autoři porovnávají tři způsoby zásahu proti epidemii: žádný zásah, plošná vakcinace a sledování kontaktů. Na základě statistických analýz mnoha běhů modelu pak autoři navrhnou kombinovaný způsob vakcinace a dávají obecná doporučení ohledně potenciálního bioteroristického útoku.

Systém EpiSimS

Příkladem rozsáhlého systému pro modelování epidemií je systém EpiSimS (Epidemiological Simulation System). Tento systém staví na reálných geografických datech

a na individuálních heterogenních agentech. Pohyb agentů po prostředí vychází z dat o denních aktivitách a dopravě, data jsou poskytována dvěma rozsáhlými externími simulačními balíky. Chování agenta je mimo jiné ovlivněno i jeho zdravotním stavem, např. agent, u kterého již nemoc propukla, zůstane doma, místo aby cestoval do práce. Agenti mají také přiřazen věk a sociální status a tyto parametry jsou zohledněny při chování agenta a při přenosu nemoci.

Systém v sobě zahrnuje předpřipravené různé způsoby zásahu proti epidemii, např. vakcinace na základě symptomů či podle sledování kontaktů nemocných osob. Jde o obecný systém, ve kterém je možné pomocí nastavení parametrů snadno modelovat různé nemoci.

Pro ilustraci zmiňme konkrétní případovou studii vypracovanou pomocí tohoto modelu (Del Valle et al., 2006). Model zachycuje okolí Los Angeles. Celkem zahrnuje 16 milionů agentů (lidí) a půl milionu míst (domy, školy, pracoviště a další). Modelovaná epidemie je pandemie chřipky, přičemž jsou zohledněny různé fáze nemoci (podobně jako u výše popsaných neštovic). Parametry jsou kalibrovány podle pandemie španělské chřipky z roku 1918. Studie s tímto modelem se zaměřují především na analýzu šíření epidemie bez zásahů a na efektivnost různých zásahů. Jak je patrné z počtu agentů a míst v modelu, jde o velmi rozsáhlý model – simulace takového modelu se provádí na výkonných paralelních výpočetních strojích a zabere řádově desítky minut.

11.5 Shrnutí

- Epidemie se dobře modelují, protože dynamika epidemie je do velké míry nezávislá na konkrétním průběhu nemoci.
- Pomocí podobných modelů můžeme zachytit velmi odlišné typy epidemií, např. biologické nemoci, počítačové viry a šíření nových technologií.
- Základní modely epidemií jsou SIS, SIR, SIRS (S = zdravý a náchylný, I = infekční, R = odolný).
- Na základním SIR modelu epidemie jsme ukázali realizaci pomocí matematického modelu, modelu s agenty a modelu na síti.
- Základní model lze dále rozšiřovat mnoha způsoby: vliv prostoru a topologie kontaktů, vliv heterogenity populace a populační dynamiky, zkoumání metod zásahu proti epidemii, mutace nemocí.
- Zkoumají se nejenom jednoduché abstraktní modely, ale také rozsáhlé modely s vysokým stupněm realističnosti.

12 Základní principy života

M: Mám další námět na model: Králíkovece. Model bude ukazovat, jak může dospět vývoj z chaotické směsi anorganických látek až na samotný vrchol stvoření – ke králíkovi.

S: Obávám se, že začínáš být příliš ambiciózní.

M: Proč? Vždyť je to prostá evoluce a na té není nic složitého: výběr nejsilnějších a dědičnost. Na modelování použiju genetické algoritmy, které jsi mně vysvětlil, a bude to.

S: To není jen tak. Tak třeba hned ten začátek. Abys mohl mluvit o dědičnosti, musíš mít něco, co se zvládne sebe-reprodukovat. Jak však vznikne látka schopná sebe-reprodukce z chaotické směsi anorganických látek?

M: Dobrá, řekněme, že tento krok pro začátek přeskočíme, a budeme předpokládat, že máme něco na styl DNA. Pak už s tou evolucí nebude problém, ne?

S: Ono přesné fungování evoluce je složitější, než se na první pohled zdá. Třeba ty genetické algoritmy není až tak těžké použít, když víš, co chceš vyvinout. Ale evoluce je otevřená, nikam nesměruje. Nebo myslíš, že je od počátku dáno, že vrcholem stvoření bude králík, a veškerá evoluce směřuje ke králíkovi?

M: Takže máme smůlu a modely jsou nám k ničemu.

S: Teď zase přeháníš na druhou stranu. Musíš si akorát dávat přiměřené cíle. Těžko zvládneme zachytit jedním modelem kompletní vývoj života. Můžeme však pomocí modelů studovat dílčí principy, a i to může být velmi zajímavé. Podívej, ukážu ti pár příkladů. . .

M: Počkej ještě, když už jsme u těch principů života, musím ti říct, co jsem zjistil při sbírání podkladů do seminárky. Díval jsem se na populační cykly, které jsi mi ukázal na modelu lovec-kořist. Zjistil jsem, že se výrazně projevují u hlodavců. Konkrétně lumíci se množí tak rychle, že jejich populační dynamika není pěkně oscilační jako u jiných tvorů, ale naprosto chaotická – někdy se strašně přemnoží, pak jsou zas úplně na vymření.

S: Já vím. Dřív se dokonce kvůli jejich rychlému množení věřilo, že během bouřky padají z nebe.

M: To ale není jediná fáma ohledně lumíků. Mnoho lidí věří, že páchají hromadné sebevraždy skokem do moře. Ve skutečnosti to ale není žádná sebevražda. Oni pouze migrují za potravou a občas se u toho utopí. Škoda, že už píšu o králících, o lumících by se našlo

taky hodně zajímavých informací. Třeba s tím migrováním – jakmile dochází potrava, začnou se společně stěhovat. Jak se ale rozhodnou? Kdo to vede? Kam jdou? Docela pochybuju, že mají nějakého lumíka-šéfa, který tomu velí.

S: No vidíš, a to se zase dostáváme ke komplexním systémům. Jedna z častých vlastností komplexních systémů je vysoká decentralizace a samo-organizace, které vedou k emergentnímu chování.

M: Počkat, zase se tady oháníš nějakými podezřelými výrazy. Co to všechno znamená?

S: Zkusím ti to popsat na lumících. Pojem „decentralizovaný“ znamená, že tam není žádný lumík-šéf, žádné jedno centrum, které by skupinu řídilo. Pojem „samo-organizovaný“ znamená, že dochází k organizaci systému – lumíci společně migrují – a tato organizace vzniká uvnitř systému, tedy vlivem interakcí mezi lumíky. Kdybychom lumíky pochytili a naházeli na nákladáky, také by organizovaně migrovali, ale nebyla by to samo-organizace. A konečně pojem emergentní chování znamená, že celek, tedy celá skupina lumíků, se chová způsobem, který nemá v rámci jednotlivce přímé období. Celá skupina organizovaně migruje, jedinci však nemají žádná pravidla pro migrování. Prostě se jen snaží nažrat, přežít, a přitom trochu kopírují, co dělají ostatní.

M: No dobře, už to trochu chápu. Ale zní to zase jako takové mlhavé pojmy, které si můžeš napasovat, na co se ti zachce.

S: To máš pravdu, často se to tak i děje. Myslím, že ani není účelné snažit se definovat tyto pojmy přesně a dohadovat se, co je a co není samo-organizovaný systém. Přínos těchto pojmů vidím v tom, že nám říkají, co se máme snažit hledat. Jakmile si myslíme, že jsme našli stopu po těchto pojmech, můžeme se pokusit tuto stopu dále sledovat a vyjádřit zmíněné vlastnosti přesněji. K tomu se nám opět hodí modely.

M: Takže třeba v případě lumíků bych se mohl snažit navrhnout model, který ukáže, jak lumíci společně organizovaně migrují, aniž by měli lumíka-šéfa nebo nákladáky.

S: Přesně tak. Víš co, pojď se podívat na ty příklady. To je v tomto případě daleko poučnější než meditovat o významu mlhavých pojmů.

12.1 Sebe-reprodukce a vznik života

Klíčový prvek života je sebe-reprodukce, tedy schopnost vytvářet svoje vlastní kopie. Co je nezbytné pro fungování sebe-reprodukce? Jak se vůbec vyvinuly první živé, sebe-reprodukcující organismy z neživé hmoty? To jsou složité otázky, které jsou nad rámec této knihy. Zde pouze popíšeme některé známé jednoduché modely, jež jsou těmito otázkami inspirovány.

Sebe-reprodukcující se automaty

John von Neumann, který se tématem sebe-reprodukce zabýval, vycházel z porovnání reprodukce v přírodě a reprodukce strojů. Při reprodukci v přírodě dochází k udr-

žení složitosti, případně dokonce k jejímu zvyšování, a můžeme tak mluvit o sebe-reprodukcí. Při reprodukci strojů však dochází vždy ke snižování složitosti – složitější stroj vyrábí stroj jednodušší.

Na základě úvah o sebe-reprodukcí se Neumann rozhodl navrhnout stroj schopný sebe-reprodukce. Nepokoušel se sestavit fyzický stroj, pracoval pouze na abstraktní úrovni a k návrhu použil buněčné automaty. Neumann navrhl automat s 29 lokálními stavy a velmi komplikovanými pravidly. Automat představuje univerzální konstruktor – dokáže sestavit jakýkoliv stroj, jehož popis dostane na vstup. Vstupní popis i výstupní stroj samozřejmě představují konfigurace buněčného automatu, nikoliv fyzické entity. Díky tomu, že automat je univerzálním konstruktorem, má i vlastnost sebe-reprodukce – pokud dostane na vstup svůj vlastní popis, vyrobí svoji kopii.

Univerzalita je vlastnost, která je pro sebe-reprodukci dostatečná, avšak rozhodně ne nutná. Živí tvorové se umí sebe-reprodukovat, ale rozhodně nejsou schopni zkonstruovat cokoli. Další výzkumníci se tedy pokoušeli zaměřit na aspekty, které jsou pro sebe-reprodukci nezbytné, a snažili se navrhnout co nejjednodušší automat, jenž by vykazoval znaky sebe-reprodukce.

Příkladem takového automatu je Langtonův cyklus (Langton, 1984), jehož chování je zachyceno na obr. 12.1. Cílem návrhu v tomto případě je, aby řízení reprodukce nebylo pasivní a nespočívalo pouze ve fixně daném mechanismu (pravidlech automatu), ale aby v reprodukci hrála aktivní roli struktura, která se sebe-reprodukuje. Automat má osm lokálních stavů, a jak je vidět z ilustračního obrázku, základem dynamiky je vzor malé čtvercové „buněk“, který se neustále kopíruje, a to paralelně na mnoha místech zároveň.


Hra Život

Výzkumem sebe-reprodukce je inspirován nejznámější buněčný automat – hra Život. Tento automat navrhl J. H. Conway, jehož původním cílem bylo najít jednoduché pravidlo s náročnou předpověditelností. Konkrétně si dal tyto cíle:

- Pro žádnou počáteční konfiguraci s konečným počtem živých buněk by nemělo být triviálně dokazatelné, že počet buněk roste nade všechny meze.
- Měly by existovat počáteční konfigurace, které (alespoň zdánlivě) rostou nade všechny meze.
- Měly by existovat počáteční konfigurace, které se vyvíjejí a mění dlouhou dobu, než upadnou do stabilního stavu.

Conwayovi se podařilo nalézt pravidla splňující tyto požadavky. Dokonce se mu tyto požadavky podařilo naplnit tak dobře, že sám nebyl schopen rozhodnout, zda existuje počáteční konfigurace s konečným počtem živých buněk, která v čase roste nade všechny meze. A tak když pravidla zveřejnil, nabídl symbolickou odměnu 50 dolarů tomu, kdo takovou konfiguraci najde nebo dokáže, že neexistuje. Během jednoho roku se týmu pracovníků z MIT podařilo takovou konfiguraci najít.

Jaká jsou tedy pravidla tohoto automatu? Jde o buněčný automat na dvourozměrné čtvercové mřížce, jako okolí buněk uvažujeme Moorovo okolí (tj. osm sousedů).



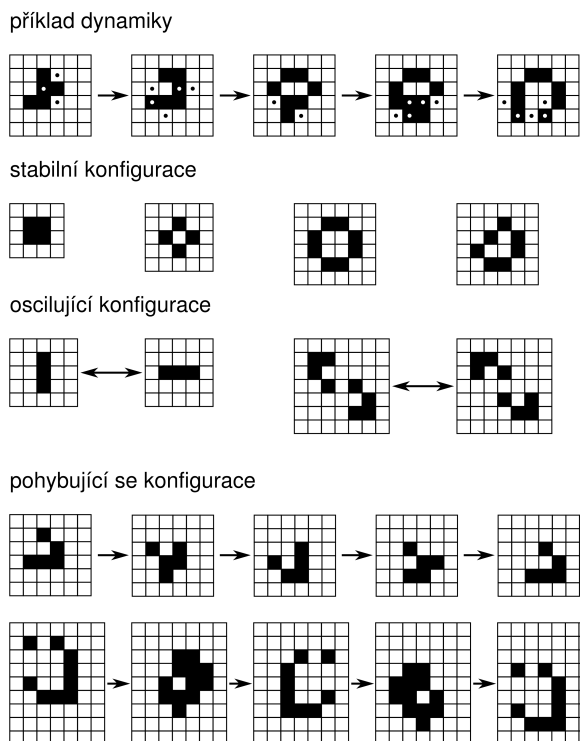
Obr. 12.1: Vývoje Langtonova sebe-reprodukcujícího se automatu.

Každá buňka může být v jednom ze dvou stavů: živá, mrtvá. Přejídné pravidlo je následující (viz též obr. 12.2):

- Pokud je buňka živá:
 - pokud má méně než dva živé sousedy, umírá na osamělost,
 - pokud má více než tři živé sousedy, umírá na přehustění,
 - pokud má dva nebo tři živé sousedy, přežívá.
- Pokud je buňka mrtvá:
 - pokud má právě tři živé sousedy, ožívá,
 - jinak zůstává mrtvá.

Hra Život nemodeluje žádný konkrétní systém, ale i tak nás může hodně naučit o komplexních systémech. Především opět ukazuje důležitý princip: jednoduchá pravidla mohou vést ke složitému chování. Tvrzení, že uvedená pravidla jsou jednoduchá, asi není příliš sporné. V čem však spočívá složitost chování? Především je tento automat výpočetně univerzální – cokoliv lze vypočítat algoritmem, lze „vypočítat“ pomocí hry Život, je pouze potřeba problém vhodně zakódovat pomocí počáteční konfigurace hry. Z toho pramení mimo jiné obtížná předpověditelnost chování automatu.

Zde nebudeme zacházet do detailních analýz různých složitých chování tohoto jednoduchého automatu, kterých je mimochodem velmi mnoho, a pouze shrneme několik zajímavých konfigurací (některé z nich jsou uvedeny na obr. 12.2):



Obr. 12.2: Hra Život. První řádek ukazuje příklad vývoje automatu, tečkami jsou označeny buňky, které během dalšího kroku změni stav. Další řádky ukazují některé zajímavé konfigurace.

- stabilní konfigurace: konfigurace, které se nemění,
- oscilující konfigurace: konfigurace, které se během několika kol dostanou do původního stavu,
- pohybující se konfigurace: konfigurace, které se během několika kol dostanou do původního rozmístění, ovšem posunou se přitom v prostoru,
- kluzákové dělo: konfigurace, která se během několika kol dostane do původního rozmístění a mezitím „vystřelí“ kluzák, což je jedna z pohybujících se konfigurací; kluzákové dělo je příklad konfigurace, která vyvrací Conwayovu hypotézu,
- rajská zahrada: konfigurace, která nemá předchůdce, tj. taková, do které se nelze pomocí pravidel dostat – dá se snadno ukázat, že musí existovat, ale je překvapivě složité ji nalézt.

Proč se tento buněčný automat vlastně nazývá Život? Citujme autora: „Je pravděpodobné, že pokud poskytneme dostatečný prostor a začneme v náhodném stavu, tak po dostatečně dlouhé době osídlí části prostoru inteligentní sebe-reprodukcující bytosti.“ Hra má tedy, dle autorových slov, schopnost z náhodného stavu vytvářet

pravidelné a zajímavé struktury, což je analogické hypotéze „prapůvodní polévky“, ve které vznikl život z náhodného shluku anorganických látek. Všimněme si, že zde nedochází k žádnému přímému kopírování, reprodukci či dědičnosti – dochází pouze k tomu, že většina konfigurací se rychle rozpadne, kdežto pár konfigurací, které jsou nějakým způsobem stabilní, se objevuje znovu a znovu a tím pádem se „množí“.

Souvislosti: O hře Život toho bylo napsáno daleko více, než její jednoduchá pravidla naznačují. Alespoň stručnou zmínku o ní lze nalézt v mnoha knihách zmíněných v seznamu literatury, podrobněji se jí zabývá například Flake (2000). Mnoho materiálů i interaktivních demonstrací však lze nalézt i na internetu.

12.2 Evoluce

Mám podezření, že neustálé novinky v biosféře pramení v nemalé míře z toho, že biosféra se čerta stará o naše potíže s určením jejího konfiguračního stavu a s kategorizací jevů. (S. Kauffman)

Evoluce je daleko komplikovanější téma, než by se mohlo zdát, a modelování hraje při studiu tohoto jevu důležitou roli. Zde ukážeme dva známé modely, které ilustrují dílčí problémy spojené se studiem evoluce.

Jestřáb a holubice

Model Jestřáb a holubice ilustruje, že neexistuje absolutní míra zdatnosti – není možné mluvit o zdatnosti organismu, aniž bychom uvážili, v jakém prostředí se pohybuje. Model také ilustruje význam důležitého pojmu „evolučně stabilní strategie“.

Model vychází z teorie her. Uvažujeme jedince, kteří soupeří o potravu a používají přitom dvě strategie. Jedinci, kteří se chovají podle strategie jestřáb, jsou bojovní a ze souboje utíkají jen při velkých poraněních. Jedinci, kteří se chovají podle strategie holubice, jsou opatrní, nikdy neútočí a ze souboje utíkají. Co se stane, když se dva jedinci střetnou nad kusem jídla? Když se setká holubice s jestřábem, jestřáb zaútočí, holubice uteče, a jestřáb tedy získá celou kořist a holubice nic. Při střetnutí dvou holubic k boji nedojde, obě čekají, až to druhá vzdá. Nakonec tedy jedna z nich potravu získá a nemusí bojovat, čekání však stojí drahocenný čas. Když se střetnou dva jestřábi, bojují spolu do posledních sil, čímž pádem je jejich průměrný zisk ze souboje záporný, protože ani získaná kořist nevyváží utržená zranění. Tabulka 12.1 vyjadřuje tento slovní popis pomocí čísel – pro každou situaci uvádí průměrný zisk z mnoha setkání (např. v rámci jednoho souboje holubice–holubice získá potravu jen jedna a bodový zisk bude 6 a 0, dlouhodobý průměr tak bude 3 a 3). Konkrétní hodnoty však nejsou příliš důležité, hlavní je uspořádání hodnot.

Co je výhodnější – být jestřáb, nebo holubice? Na tuto otázku neexistuje přímočará odpověď, protože záleží na tom, jaké je složení populace. Pokud v populaci

Tabulka 12.1: Model jestřáb a holubice, příklad tabulky konkrétních hodnot.

	jestřáb	holubice
jestřáb	-2; -2	10; 0
holubice	0; 10	3; 3

převažují holubice, je velmi výhodné být jestřábem – málokdy utřím zranění ze souboje a skoro vždy získám jídlo. Pokud však v populaci převažují jestřábi, je lepší být holubicí – sice nezískám moc jídla, ale alespoň se obejdu bez těžkých zranění.

Zapišme tuto situaci matematicky. Předpokládejme, že podíl jestřábů v populaci je p (a podíl holubic tedy $1 - p$). Potom průměrný zisk jestřába je: $z_j = -2p + 10(1 - p) = 10 - 12p$ a průměrný zisk holubice je: $z_h = 0p + 3(1 - p) = 3 - 3p$. Pokud v populaci převažují jestřábi (p je blízko jedné), pak platí $z_h > z_j$ (je výhodnější být holubicí). Pokud převažují holubice (p je blízko nuly), pak platí $z_h < z_j$ (je výhodnější být jestřábem).

Jaká strategie tedy převáží v evolučním vývoji? Aby strategie zcela dominovala, musela by být evolučně stabilní – to znamená, že pokud by do populace tvořené čistě touto strategií přišla strategie cizí, pak by se nerozšířila. Jak však naznačuje výše uvedená analýza, ani jedna ze zmíněných strategií evolučně stabilní není. Při vývoji však dojde k ustanovení stabilního poměru jestřábů a holubic ($p = 7/9$, což je řešení rovnice $z_j = z_h$).

Pokud bychom dovolili složitější strategie, evolučně stabilní strategie existovat bude. Takovou strategií je například „odvetník“ (neútočí, ale pokud je na něj zaútočeno, tak oplácí) nebo mixovaná strategie „chovej se jako jestřáb s pravděpodobností $7/9$, chovej se jako holubice s pravděpodobností $4/9$ “.

Souvislosti: Model Jestřáb a holubice navrhli J. M. Smith a G. Price, tento model se stal hojně používaným a je rozebírán v mnoha zdrojích, viz např. Dawkins (1976), Flegr (2006), Gilbert a Troitzsch (2005). Výsledky, které jsme zde pouze zběžně načrtli, lze získat a dále prohloubit pomocí dalších rozšíření a analýz modelu. Hlubší analýzy necháváme jako doporučené cvičení pro čtenáře, viz příloha D.

Tierra

Přesněji řečeno – v přírodě probíhá spíše koevoluce než evoluce. Nemáme zde žádné absolutní měřítko zdatnosti jedince (síly, schopnosti reprodukce). Zdatnost je relativní, protože závisí na prostředí, ve kterém se jedinec vyskytuje. Evoluce tedy nesměruje k jakémusi danému optimu, ale vytváří organismy, jež jsou schopny co nejlépe využít aktuální situace. Tento rozdíl můžeme osvětlit metaforou s hledáním vysokého kopce v krajině, přičemž klasické optimalizační úlohy si můžeme představit

jako prosté šplhání do kopce s cílem dostat se co nejvýš. Koevoluce v této metafoře představuje šplhání do kopce v plastické krajině, která průběžně mění svůj tvar, mimo jiné díky tlaku šplhajícího jedince. Říkáme, že evoluce je otevřená – nesměřuje k žádnému ideálnímu vrcholu, ale stále produkuje nové druhy.

Tierra je model digitálních organismů, který představuje pokus o zachycení otevřené evoluce. Prostředím v tomto modelu je virtuální počítač a organismy jsou jednoduché programy, které soutěží o dostupnou paměť a o čas, po němž mohou využívat procesor. Procesorový čas je zde analogií energie a počítačová paměť analogií materiálu.

Programy jsou sekvence jednoduchých instrukcí (32 různých 5bitových instrukcí ve zjednodušeném assembleru). Autor modelu ručně vytvořil „prapředka“ – jednoduchý program, který dělá pouze to, že kopíruje sám sebe. Model se tedy nepokouší zachytit vznik života, základní schopnost sebe-reprodukce je tu „dána shora“. Dál už je však vývoj zcela ponechán evoluci. Model funguje podobně jako klasický genetický algoritmus: z prapředka pomocí mutací a kombinací vznikají nové programy, ty bojují o zdroje, úspěšnější se množí, neúspěšní umírají.

Oproti klasickému použití genetických algoritmů je na tomto modelu zajímavé, že neobsahuje žádnou externě danou funkci zdatnosti, která by se v modelu maximalizovala. Funkce zdatnosti je implicitně zadána uvnitř modelu – jsou dána pravidla přežití, a kdo zvládne přežít a namnožit se, ten je úspěšný. V principu tento přístup umožňuje otevřenou evoluci, tedy vývoj, který nesměřuje dopředu daným směrem nebo k určitému konečnému stadiu.

Dynamika modelu je velmi zajímavá. V průběhu simulace se záhy objevují paraziti – tyto programy využívají pro svoje kopírování zdrojový kód jiných programů, který zavolají jako funkci, jež se po ukončení vrátí do těla jejich programu. Díky tomuto parazitování je jejich vlastní kód kratší a tím jsou úspěšnější. Později se objevují i hyperparaziti, kteří dokáží zneužívat parazitů – využijí toho, že parazit zavolal jejich kód, a pak už mu volání nevrátí zpět.

Přestože má model bohatou a zajímavou dynamiku a existuje několik jeho dalších rozšíření, vývoj digitálních organismů se vždy po čase ustálí. Nedochází tedy k evoluci, při které by vznikaly stále nové a nové „druhy“. Otázka, jak digitálně modelovat opravdu otevřenou evoluci, zůstává zatím nezodpovězená.

Souvislosti: Základní model Tierra navrhl Ray (1991). Autor model dále rozšířil a rozebral v dalších pracích (na jeho webových stránkách lze najít řadu materiálů včetně videa). Principy evoluce se zabývá také kapitola 14, ve které je probrán vývoj spolupracujícího chování a altruismu.

12.3 Samo-organizace

Jedním ze zajímavých principů života je schopnost samo-organizace, která se projevuje na mnoha úrovních od jednobuněčných organismů až po skupiny lidí. Se

samo-organizací souvisí dále pojmy jako decentralizované řízení a emergentní chování. Všechny tyto pojmy jsou stručně charakterizovány ve slovníku v příloze A. Zde se nebudeme pouštět do podrobnějších rozborů pojmů, zvolíme raději ilustraci na příkladech.

I když se v této části objevují jména živočichů, jsou uvedené modely značně abstraktní a rozhodně neslouží jako věrný popis chování konkrétního druhu. Cílem modelů je pouze ilustrovat aspekty, které se týkající samo-organizace.

Souvislosti: Detailní rozbor tématu samo-organizace s mnoha rozsáhlými případovými studiemi podává Camazine et al. (2003). Populární výklad o samo-organizaci a emergentním chování nabízí Johnson (2001).

Hlenka


Hlenka je tvor, který prochází zajímavým životním cyklem. Část života tráví v podobě samostatných jednobuněčných organismů, část života jako jeden mnohobuněčný organismus. Biologové, kteří hlenku intenzivně studují, se zabývají mimo jiné otázkou, jak dochází k přechodům mezi jednobuněčným a mnohobuněčným stadiem. Experimentálně bylo zjištěno, že k tomuto přechodu dochází při nedostatku potravy a že při shlukování hrají roli feromony. Feromon je obecné označení pro chemickou látku využívanou pro vnitrodruhovou komunikaci.

Dlouhou dobu převládala hypotéza speciálních buněk (v angličtině jsou tyto buňky označovány termínem „pacemaker cell“, což lze doslova přeložit jako „buňka, která udává tempo“). Tato hypotéza předpokládá, že existují speciální buňky, které shlukování odstartují a kolem nichž se ostatní buňky shromáždí. Jde tedy o typicky centralizované vysvětlení. Biologové však dotyčné buňky nemohli najít. Není divu – zdá se totiž, že ani neexistují. Shlukování totiž pravděpodobně funguje zcela decentralizovaně. Princip shlukování bez přítomnosti speciálního typu buněk lze ilustrovat na jednoduchém modelu.

Jde o ABM model, ve kterém agenti představují jednotlivé buňky hlenky. Jako prostředí využíváme dvourozměrnou mřížku, u které každé pole může nést feromonovou stopu. Agenti-buňky se pohybují náhodně po prostoru, přičemž při svém náhodném pohybu mírně upřednostňují místa s větším množstvím feromonu. Současně s pohybem sami vylučují feromon – polím mřížky, přes které přešel agent-buňka, se množství feromonu zvýší. Feromon se průběžně vypařuje.

Typické chování modelu je znázorněno na obr. 12.3. Na začátku simulace jsou agenti-buňky náhodně rozmístěni po prostoru. Rychle vznikne několik malých shluků, a ty se posléze postupně spojují. Jde o typický systém ovládaný zpětnými vazbami. Shlukování řídí pozitivní zpětná vazba: čím víc buněk na jednom místě, tím víc feromonu v okolí, tím víc buněk přijde na toto místo. Tento efekt vyvažuje negativní zpětná vazba: čím větší shluky, tím méně volných buněk, tím menší nárůst velikosti shluků.

Model ilustruje také fenomén fázového přechodu. Při některém nastavení parametrů (počet buněk, rychlost pohybu, rychlost vypařování) k žádnému shlukování



Obr. 12.3: Model shlukování hlenky: černé šipky představují jednobuněčné hlenky, stupně šedé znázorňují množství feromonu.

nedochází. Jakmile však překročíme určitou mez, dochází okamžitě k velkému shlukování, přičemž v podstatě neexistuje žádný mezistav (mírné shlukování).


Mravenci

Jdi k mravenci, dívej se, jak žije, ať zmoudříš. Ač nemá žádného vůdce, dozorce či vládce, opatřuje si v létě pokrm, o žnách sklízí svou potravu.
(Příslaví 6:6–8)

Postupme ve vývojovém žebříčku o krok dále. Mravenci jsou jeden z nejúspěšnějších živočišných druhů a v mnoha ohledech přinejmenším konkurují namyšleným pánům tvorstva, např. obývají téměř celou planetu a tvoří až 15 % biomasy tropických pralesů. Kromě toho, že jsou úspěšní, jsou také velmi zajímaví. Mravenci (a obecněji sociální hmyz) jsou typickou ukázkou decentralizovaného, samo-organizujícího se systému. Označení mravenčí královna, které připomíná hierarchické uspořádání středověké lidské společnosti, je v tomto případě zavádějící. Mravenčí královna je spíše stroj na kladení vajíček nežli řídicí element.

Mravenci jsou také pěkným námětem pro modelování, konkrétně pro modelování s agenty. Zde popíšeme jednoduchý model sběru potravy. Agenti představují mravence. Jako prostředí používáme dvourozměrnou plochu, ve které je umístěno mraveniště a zdroj potravy. Podobně jako u modelu hlenky prostředí opět může nést feromonové stopy a agenti-mravenci se pohybují náhodně po prostoru a při pohybu upřednostňují směr, ve kterém je vyšší koncentrace feromonu. Pokud mravenec narazí na potravu, tak ji zvedne a vydá se směrem do mraveniště – model zjednodušeně předpokládá, že mravenec cestu zpět najít umí. Cestou do mraveniště mravenec vypouští feromon, který se postupně vypařuje.

Obr. 12.4 ilustruje typické chování modelu. Na začátku chodí mravenci nahodile, jakmile však několik mravenců najde zdroj potravy, rychle se vytvoří „feromonová dálnice“, kterou sledují ostatní mravenci. Jde o typickou pozitivní zpětnou vazbu: čím víc mravenců potravu najde, tím více feromonu je na cestě a tím více mravenců



Obr. 12.4: Mravenci a sběr potravy. Velký černý kruh představuje mraveniště, menší tmavě šedý kruh zdroj potravy. Odstíny šedé znázorňují feromonové stopy.

potravu najde. Pokud do modelu přidáme více zdrojů potravy, zjistíme, že chování mraveniště je také „inteligentní“ – potrava je čerpána ze zdrojů podle vzdálenosti.

Na tomto modelu můžeme dobře ilustrovat princip emergentního chování. Emergentní chování je chování na úrovni celku, které nemá žádný přímý vzor v chování či pravidlech jednotlivých částí. Jako opak emergentního chování můžeme chápat předepsané chování, což je chování na úrovni celku, které je přímým důsledkem určitého pravidla jednotlivých částí. V uvedeném modelu je tedy hledání cesty do mraveniště předepsaným chování, protože v modelu je přímo řečeno, že jakmile mravenec najde potravu, má jít přímo zpět do mraveniště. Na tom, že mravenci spořádaně nosí potravu do mraveniště, tedy není nic překvapivého. Naproti tomu efektivní hledání cesty k potravě je emergentní chování, protože cesta k potravě není přímo v pravidlech mravenců zakódovaná. Mravenci pouze mají jednoduchá pravidla týkající se zanechávání feromonu a sledování feromonu, ze kterých není způsob chování celku jednoduše odvoditelný.


Nejen tento model, ale mraveniště obecně jsou typickou ukázkou emergentních vlastností (Gordon, 1999). Přestože jednotliví mravenci jsou velmi jednoduší, žijí krátkou dobu a dokáží zpracovávat jen jednoduché podněty ve svém bezprostředním okolí, mraveniště jako celek přežívá dlouho a má svoji „inteligenci“ a „osobnost“. Například mladé mraveniště je spíše agresivní a expanzivní, kdežto staré mraveniště je poklidné a ustálené, a to i přesto, že průměrné stáří jednotlivých mravenců bude v obou velmi podobné.

Hejno

Samo-organizace a decentralizované řízení se ovšem vyskytuje nejen u jednoduchých tvorů. Dalším příkladem může být chování ptáků, kteří vytvářejí hejna. Hejno často zdálky vypadá jako relativně uspořádaný celek, jeho chování je však do značné míry důsledkem lokálních interakcí.

Samo-organizované chování hejna můžeme opět ilustrovat ABM modelem, ve kterém jednoduchá lokální pravidla na úrovni jednotlivců (ptáků) vedou k organizovanému chování na úrovni celku (hejna). Agenti tentokrát představují ptáky. Jako pro-

středí používáme torus – dvourozměrnou mřížku s propojenými okraji (levý s pravým, horní s dolním). Každý agent-pták letí konstantní rychlostí svým směrem, přičemž tento směr mírně mění podle tří pravidel:



Obr. 12.5: Model hejna – postupné vytváření hejna z počátečního náhodného stavu.

1. Vyhýbání se: nebuď příliš blízko ostatním ptákům.
2. Kopírování: pohybu se podobným směrem jako ostatní ptáci.
3. Střed: snaž se být uprostřed hejna.


Obr. 12.5 ilustruje typickou simulaci. Na počátku mají jednotliví agenti-ptáci náhodnou polohu a náhodný směr. Po spuštění simulace se začnou ptáci rychle shromažďovat a vytváří realisticky vypadající hejna. Model lze dále rozšířit například o trojrozměrný prostor, překážky nebo dravce, před kterými ptáci utíkají. Rozšíření modelu se využívají v počítačové grafice pro vytváření realistických animací.

Souvislosti: Modely uvedené na obr. 12.3, 12.4 a 12.5 pocházejí z knihovny nástroje NetLogo (Wilensky, 1998). Původním autorem modelů shlukování hlenky a sběru potravy mravenců je Resnick (1997), autorem modelu hejna je Reynolds (1987).

12.4 Homeostáza

Homeostáza je schopnost systému udržovat rovnováhu pomocí regulačních mechanismů. Příklady homeostázy jsou buňka udržující vhodné vnitřní pH nebo organismus regulující tělesnou teplotu na téměř konstantní úrovni. O homeostáze však můžeme mluvit i na úrovni vyšších systémů, například na úrovni ekosystému. Ve všech těchto příkladech je homeostáza založena na vyvážených zpětných vazbách v systému.

Zde ilustrujeme princip homeostázy na jednoduchém abstraktním modelu, který navrhl James Lovelock na podporu své hypotézy Gaia. Hypotéza Gaia zjednodušeně řečeno tvrdí, že živá hmota na planetě Zemi funguje jako jeden organismus udržující si vhodné podmínky pro život, a že tedy dochází k homeostáze na úrovni života jako celku. Model, který zmíníme, se nepokouší modelovat život na Zemi, ale pouze ilustruje základní myšlenku hypotézy Gaia na abstraktním příkladě.



Obr. 12.6: Svět sedmikrásek: hlavní vztahy.

Svět sedmikrásek

Svět sedmikrásek je imaginární svět, ve kterém rostou pouze dva druhy rostlin: černé a bílé sedmikrásky. Růst rostlin závisí pouze na teplotě, přičemž oba druhy sedmikrásek mají stejnou závislost růstu na teplotě (růstovou křivku). Černé sedmikrásky ovšem záření ze slunce absorbují a tím ohřívají svoje okolí, kdežto bílé sedmikrásky záření odrážejí a tím své okolí ochlazují.


Růst sedmikrásek je tedy závislý na teplotě, ovšem současně také teplotu ovlivňuje, protože sedmikrásky mění albedo (odrazivost) celé planety a tím ovlivňují teplotu, která následně ovlivňuje jejich vlastní růst. Jde tedy o systém do velké míry ovládaný zpětnými vazbami (viz obr. 12.6). Tato vlastnost se dobře projeví v situaci, kdy pomalu zvyšujeme zářivost slunce, které svět sedmikrásek ohřívá. Díky zpětným vazbám jsou sedmikrásky jako celek schopny částečně regulovat teplotu a dosahovat tak homeostázy na úrovni celého světa.

Modely světa sedmikrásek

Svět sedmikrásek lze modelovat pomocí systémové dynamiky nebo pomocí pravděpodobnostního buněčného automatu. Pro srovnání stručně popíšeme oba modely.

V systémovém modelu máme zásobárny, které určují celkovou plochu planety pokrytou černými sedmikráskami, bílými sedmikráskami a volnou plochou. Struktura modelu rámcově odpovídá obr. 12.6. Zásobárny jsou propojeny oboustrannými toky, velikost toků závisí na teplotě podle růstové křivky parabolického tvaru. Vnější (externě zadané) parametry modelu jsou zářivost slunce a albedo obou druhů sedmikrásek. Vnitřní parametry, které jsou vypočítány na základě hodnoty zásobáren a vnějších parametrů, jsou teplota plochy pokryté černými sedmikráskami, teplota plochy pokryté bílými sedmikráskami a celková průměrná teplota. Na těchto vnitřních parametrech pak závisí změna velikosti hlavních zásobáren. Celkově model obsahuje zhruba deset rovnic.

Model pomocí buněčného automatu využívá pravidelnou čtvercovou mřížku, na které je každé pole mřížky buď prázdné, nebo obsazené jednou sedmikráskou. Teplota každého pole mřížky závisí primárně na aktuální zářivosti slunce a na albedu pokrytí daného pole. Krom toho se teplota z každého políčka šíří do okolí, tj. v každém kroku se průměruje s teplotou na okolních polích. Každá rostlina žije náhodně dlouhou dobu. Na volném políčku může začít růst nová rostlina, přičemž pravděpodobnost,



Obr. 12.7: Model světa sedmikrásek pomocí buněčného automatu. Barva na pozadí odpovídá teplotě – čím světlejší barva, tím vyšší teplota. V prvním případě je zářivost slunce malá (dominují černé sedmikrásky absorbující záření), v druhém optimální (rovnoměrné zastoupení obou druhů) a ve třetím případě je zářivost vysoká (dominují bílé sedmikrásky odrazující záření).


že se tak stane, závisí na teplotě políčka (podle růstové křivky) a na tom, co roste v bezprostředním okolí. Obr. 12.7 znázorňuje ilustraci běhu modelu.

Výsledky simulace

Obr. 12.8 znázorňuje numericky zpracované výsledky simulace. V průběhu simulace postupně roste zářivost slunce podle externě zadané funkce. Dokud je sluneční zářivost nízká, na planetě rostou převážně černé sedmikrásky a tím zvyšují teplotu. Jak teplota slunce stoupá, klesá podíl černých a roste podíl bílých sedmikrásek. Teplota se tak udržuje na relativně stabilní úrovni. V určitém okamžiku už ani vysoké albedo bílých sedmikrásek nestačí na ochlazování planety a dojde k prudkému kolapsu života a vysokému nárůstu teploty. Simulace tedy názorně ukazuje, jak sedmikrásky regulují teplotu pro svůj prospěch. Systém jako celek dosahuje homeostázy.

Model lze dále rozšiřovat například o katastrofy a o více druhů sedmikrásek. Kromě více druhů rostlin byla zkoumána rozšíření i s králíky (býložravci) a liškami (masožravci). Analýzy těchto rozšířených modelů ukázaly, že systém je stabilnější a dokáže se lépe vyrovnávat s katastrofami, když je přítomno více druhů a vazby jsou komplikovanější (např. za přítomnosti masožravců). Rozšířený model tak poskytuje mimo jiné také argumenty pro zachování biodiverzity.

Souvislosti: Původními autory modelu světa sedmikrásek jsou Watson a Lovelock (1983). Detailnější rozbor včetně několika rozšíření modelu rozebírají Lenton a Lovelock (2001). Zobrazený model s agenty pochází z knihovny modelů nástroje NetLogo (Wilensky, 1998).



Obr. 12.8: Svět sedmikrásek: výsledky simulace modelu (buněčný automat). Levý diagram ukazuje průměrnou teplotu na planetě v přítomnosti sedmikrásek ve srovnání s holou planetou. Pravý diagram znázorňuje, jak se s rostoucí teplotou mění druhové složení na planetě.

12.5 Shrnutí

- Pomocí modelů můžeme ilustrovat dílčí principy fungování života, jejichž pochopení je často náročnější, než se na první pohled zdá.
- V této kapitole jsme ukázali vesměs jednoduché a velmi abstraktní modely. Opět narážíme na princip, že jednoduchá pravidla mohou vést k složitým, zajímavým a těžko předpověditelným chováním (například buněčný automat Život).
- Modely sebe-reprodukce se zabývají hledáním nutných podmínek pro existenci sebe-reproduktivního chování.
- Model Tierra představuje pokus o zachycení otevřené evoluce pomocí digitálních organismů soupeřících v prostředí virtuálního počítače.
- Model Jestřáb a holubice ukazuje význam proměnlivého prostředí v evoluci.
- Samo-organizace je schopnost systému organizovat se bez centrální autority nebo vnějšího zásahu. Pro dosažení samo-organizace je klíčová role pozitivní zpětné vazby. Uvedli jsme příklady samo-organizace na abstraktních modelech hlenky, mravenců a hejna.
- Svět sedmikrásek je jednoduchý model imaginárního světa, který byl vytvořen na podporu složité hypotézy o fungování Země jako celku. Model ilustruje princip homeostázy.
- Popsané modely využívají škálu rozličných technik: buněčné automaty, ABM modely, systémové modely, genetické algoritmy, teorie her.

Souvislosti: Základními principy fungování života a jejich modelováním se detailně zabývá Kaufman (2000). Co se týče modelování života na vyšších úrovních (např. konkrétní živočichové, ekosystémy), dobrý přehled výpočetního modelování pomocí agentů podává Grimm a Railsback (2005), klasické matematické modely lze najít ve většině učebnic ekologie, např. Krebs (2001).

13 Modelování sociálních a ekonomických systémů

M: Rozhodl jsem se dát do seminárky pár slov o ekonomickém významu králíků. Tak mě napadlo udělat jednoduchý model „králíčí ekonomiky“. Měl bych tam sedláky, kteří se každý rok rozhodují, kolik králíků si nechají na chov a kolik jich prodají na maso a kožky. Výkupní ceny by závisely na poptávce a nabídce. To by mohlo být docela zajímavé, ale asi by to nebylo moc užitečné, že?

S: Kdepak, takové jednoduché modelové ekonomiky se opravdu používají. Cílem modelů není předpovídat cenu králíčích kožek na světových trzích, ale spíše lépe pochopit, jak vůbec funguje opravdový trh. Klasické ekonomické teorie jsou založeny na předpokladu racionality, ovšem reální agenti na trhu se racionálně nerozhodují. Spíše se učí kopírováním od ostatních a zkušenostmi, podobně jako králíci, kteří si pamatují, kde roste nejlepší tráva.

M: Dobře, takže bych případně v tom modelu králíčí ekonomiky neměl používat racionální agenty, ale spíše agenty s induktivním myšlením. Ale stále mi není jasné, co tím získám.

S: Na úrovni jednoduchého modelu tím získáš především lepší vhled do fungování trhu. V klasickém ekonomickém uvažování dominuje negativní zpětná vazba: nabídka se reguluje poptávkou, z toho se deduktivně odvodí rovnováha, trh je stabilní. Jakmile ale přijmeš induktivní myšlení a omezení na racionalitu, hned se ti do systému vloudí pozitivní zpětné vazby, které mohou systém vyvést z rovnováhy. Tak dostaneš reálnější chování modelu a lépe pochopíš skutečnost.

M: Nevím, mám z toho trochu divný pocit. U modelu s králíky mi zjednodušení v modelu přijdou ještě přijatelná. Ale jakmile začneme dělat modely lidí, tak se mi to nezdá. Lidé jsou strašně složití a nemůžeš jejich myšlení zjednodušit na tři pravidla.

S: To je jen otázka, z jaké úrovně se na člověka díváš. Pokud se snažíš pochopit uvažování holky, se kterou bys rád randil, tak pravděpodobně nebudou tři pravidla stačit. Pokud tě ale zajímá celkové chování davu lidí, mohou být tři pravidla zcela dostatečná. V mnoha ohledech nejsou lidé od těch králíků zas tak odlišní.

13.1 Pozitivní zpětná vazba v ekonomii

V oblasti sociálních systémů, především v ekonomii, se modelování používá již dlouho. Klasické ekonomické modely jsou inspirovány fyzikálními modely jednoduchých systémů a sestávají z několika málo rovnic, u kterých analyticky hledáme řešení (většinou ekvilibrium). V určitých situacích, především tehdy, kdy v systému dominuje negativní zpětná vazba a existuje unikátní ekvilibrium, je tento přístup dostatečný a užitečný. Často však máme v systému výrazné pozitivní zpětné vazby, existuje více ekvilibríí a zajímá nás i chování systému mimo ekvilibrium. V takových případech s klasickými modely nevystačíme a musíme se podívat na ekonomiku jako na komplexní systém.

Jako obvykle nebudeme tyto pojmy rozebírat v plné šíři, ale podíváme se na konkrétní příklady, které zmíněné rozdíly ilustrují. Dobrým příkladem rozdílných pohledů na ekonomiku je třeba problém klesajících a rostoucích výnosů.

Souvislosti: Klasické ekonomické modely lze najít v běžných učebnicích ekonomie, viz například Samuelson a Nordhaus (1991). Dobrý přehled výpočetních modelů v ekonomii dává Tesfatsion a Judd (2006).

Klesající a rostoucí výnosy

Co se stane, když v rámci ekonomické aktivity zvýšíme vstupy? Dá se očekávat, že vzrostou i výnosy. Otázka však je, o kolik vzrostou (příslušný ekonomický pojem je „výnosy z rozsahu“). Představme si farmáře, který obdělává zemědělskou plochu. Když zvýší množství plochy, kterou bude obdělávat, zvýší se i jeho výnosy. Další zvyšování obdělávané plochy opět povede k navýšení výnosů, ale velikost tohoto navýšení se bude zmenšovat, protože farmář bude postupně muset obdělávat plochu, která je méně úrodná nebo vzdálenější od jeho statku. Podobný princip funguje například pro těžební průmysl (nejdříve se vytěží snadno dostupné uhlí, pak výnosy klesají) a obecně pro většinu průmyslových a zemědělských odvětví. Vývoj trhu v této situaci většinou vede k ustanovení rovnováhy mezi větším množstvím konkurentů.

Ovšem když se podíváme na hi-tech odvětví a znalostní ekonomiku, vypadá situace úplně jinak. V této oblasti jsou většinou velké fixní náklady spojené s vývojem, kdežto prodej každého dalšího kusu výrobku už je velmi levný (např. software, léky). Navíc se přidávají další efekty: čím víc lidí má určitý výrobek (operační systém, přehrávač hudby, operátora mobilního telefonu), tím výhodnější je si daný výrobek pořídit, protože můžete snadněji sdílet užitek výrobku se svými kamarády. Oproti zemědělství a těžebnímu průmyslu zde naopak se zvětšujícími se vstupy výnosy mohou výrazně vzrůst. Vývoj trhu v této situaci většinou vede ke stavu „vítěz bere vše“.

Rostoucí výnosy rozhodně nejsou marginální jev a netýkají se jen obchodování jedné dílčí firmy. Ostatně proč se používá klávesnice QWERTY? Proč trhu s osobními počítači dominují počítače Intel s operačním systémem Windows („Wintel“)? Proč sídlí velké množství hi-tech firem zrovna v „Silicon valley“ v Kalifornii? Proč jdou hodinky po směru chodu hodinových ručiček?

Souvislosti: Tématem rostoucích výnosů se široce zabývá Brian Arthur, viz Arthur (1990), Arthur (1994b), Arthur (1996). Sterman (2000) věnuje této problematice rozsáhlou kapitolu, která je orientovaná především na využití těchto principů při řízení firmy.

Pólyova urna

Uvedeme velmi jednoduchý model ilustrující základní princip, který stojí za chováním systémů řídicích se zákonem rostoucích výnosů. Základní verzi tohoto modelu navrhl matematik G. Pólya:

- Máme urnu s černými a bílými kameny, ze které postupně kameny taháme.
- Na začátku máme vytažený jeden černý a jeden bílý kámen.
- Urna je kouzelná, protože pravděpodobnost, že z ní vytáhneme černý kámen, je přímo úměrná podílu doposud vytažených černých kamenů.
- Zajímá nás poměr vytažených černých a bílých kamenů v dlouhodobém horizontu.


Pro srozumitelnost uvedeme příklad: na začátku máme vytažený jeden černý a jeden bílý kámen, pravděpodobnost vytažení černého je tedy 50 %; vytáhneme černý kámen, a máme tedy dva černé a jeden bílý, pravděpodobnost vytažení černého se změnila na 66,6 %; v dalším tahu vytáhneme bílý kámen a máme dva černé a dva bílé, pravděpodobnost vytažení černého se tedy vrací na 50 %; a tak dále.

Na tomto místě je velmi vhodné, aby si čtenář zkusil na papíře odsimulovat prvních pár tahů a aby se pokusil odhadnout dlouhodobé chování tohoto modelu. Bude poměr černých kamenů oscilovat kolem hodnoty 50 %? Bude vývoj konvergovat k jednobarevnému výběru? Nebo k jinému poměru? Nebo se model bude chovat zcela náhodně? Přestože jsou pravidla modelu velmi jednoduchá, lidé odhadují chování téměř vždy špatně – model mimo jiné ukazuje, u jak jednoduchých systémů již naše intuitivní uvažování selhává.


Jak to tedy je? Odpověď naznačuje obr. 13.1, který ukazuje vývoj několika simulací tohoto modelu. Je vidět, že počáteční náhodné tahy stanoví určitý poměr, kterého se systém poté nadále drží. Lze dokonce analyticky dokázat, že jakýkoli poměr má stejnou šanci na to „být zvolen“.

Pokud model mírně upravíme a pravděpodobnost vytažení černého kamene změníme na nelineárně závislou na poměru kamenů, pak poměr v dlouhodobém horizontu konverguje buď k 0, nebo k 1 (viz obr. 13.2).

Tento model názorně ukazuje, jak se může kombinovat náhoda, pozitivní a negativní zpětná vazba. Náhoda v prvních tazích zajišťuje nepředpověditelnost vývoje modelu. Zpětné vazby pak zajišťují, že dojde k „uzamčení“ konfigurace. Systém dospěje do určitého stabilního stavu. Situaci můžeme přirovnat k chování míčku v krajině: na začátku je míček na kopci, který se pomalu svažuje, krajina je zde jen mírně zvlněná, ale postupně se míček dostává do čím dál hlubších údolí, náhoda rozhodne, do kterého údolí se míček skutálí, nicméně jakmile už je míček v jednom z údolí, tak už v něm zůstane a drobné náhodné výkyvy s tím nic neudělají.



Obr. 13.1: Pólyovy urny: deset simulací základního modelu.



Obr. 13.2: Nelineární varianta Pólyovy urny: první graf ukazuje příklad nelineární závislosti pravděpodobnosti na aktuálním poměru, druhý graf zobrazuje výsledky deseti simulací pro tuto nelineární závislost.

Model Pólyovy urny je sice velmi jednoduchý abstraktní model, nicméně v hrubých obrysech ukazuje princip, které stojí za všemi výše uvedenými příklady (pravá strana vozovky, kombinace Wintel, klávesnice QWERTY, Silicon valey). Typickým příkladem vykazujícím chování zachycené Pólyovou urnou je situace dvou firem soutěžících o dominanci na trhu s novým produktem. Konkrétním příkladem je trh s videokazetami, kdy proti sobě stály dva produkty (VHS, Betamax), které poskytovaly stejné možnosti, vzájemně však byly nekompatibilní. Na začátku rozhodla v podstatě náhoda o tom, ke komu se zákazníci přiklonili (VHS), jakmile však jeden z produktů získal převahu na trhu, tak už si ji snadno udržoval, protože noví zákazníci se spíše přiklonili k převažujícímu výrobku.

Souvislosti: George Pólya navrhl a analyzoval tento model v první polovině 20. století v rámci studia pravděpodobnosti, nikoliv jako model šíření Windows či videokazet. Tento ekonomický kontext model získal až později, rozebírá jej důkladněji například Sterman (2000).

13.2 Modelování trhu

V kapitole 6 jsme stručně nastínili rozdíly mezi analytickými modely a výpočetními modely. Zde tyto rozdíly ilustrujeme na konkrétním ekonomickém příkladě.

Jednoduchý model trhu

Uvažme jednoduchý trh, na kterém obchodníci mohou nakupovat pouze dva druhy aktiv. Zaručený vklad přináší pevný zisk r % (fixní úroková míra) a je do něj možno investovat neomezené množství peněz. Rizikové akcie vynášejí každé kolo dividendy, což je vnější veličina nezávislá na situaci na trhu. Akcií je k dispozici pouze omezené množství, aktuální cena akcií závisí na poptávce a nabídce.

Obchodování na trhu probíhá v diskretních kolech. Na začátku každého kola je zveřejněna aktuální hodnota výnosu dividend. Obchodníci se podle aktuální situace rozhodují, jaká je jejich poptávka po nákupu či prodeji akcií. Na základě poptávky a nabídky se určí cena, proběhne prodej a všechny zbylé peníze jsou investovány do zaručeného vkladu. Cílem obchodníků je samozřejmě vydělat co nejvíce peněz.

Klasická analýza

Klasická ekonomická analýza takového trhu vychází z následujících předpokladů:

- agenti jsou homogenní – všichni mají stejné informace o trhu a používají tyto informace stejným způsobem,
- agenti jsou plně racionální ve smyslu „dokáží dělat libovolně komplikovaná logická odvození“,
- agenti znají přesný mechanismus určování ceny,
- agenti ví, že všichni ostatní agenti ví vše výše uvedené.

Na základě těchto předpokladů můžeme model řešit analyticky. Pomocí rovnic vyjádříme jak fungování vlastního trhu, tak uvedené předpoklady o agentech. Z těchto rovnic deduktivně odvodíme očekávání agentů o budoucím vývoji a pomocí těchto očekávání také nabídku a poptávku po akciích, a tedy i cenu akcií. I pro tento jednoduchý model jsou rovnice relativně komplikované, nicméně jsou řešitelné i ručně. Výsledkem analýzy je fundamentální cena akcií, která kopíruje náhodné výchyly ve výnosu dividend. Díky těmto výsledkům nám analytický model pomáhá uvažovat o vztahu investování do zaručených vkladů a nejistých akcií.

Předpoklady, ze kterých analýza vychází, jsou však značně restriktivní a kvůli tomu jsou výsledky modelu hodně vzdáleny realitě. Protože všichni agenti jsou homogenní a racionální, obchodování je minimální a nedochází ke spekulacím, bublinám, krachům. Na skutečných trzích se ovšem obchoduje a spekuluje hodně. Je rozdíl způsoben tím, že v našem jednoduchém modelu máme jen dva druhy aktiv, nebo spíše předpokladem racionality?

Výpočetní model

Cílem výpočetního modelu je realističtější modelování trhu včetně spekulací, bublin a krachů. Místo homogenních a racionálních agentů používáme agenty heterogenní a omezeně racionální. Namísto deduktivního uvažování, které je typické pro klasickou analýzu, necháváme agenty uvažovat induktivně. Agenti pozorují trh a pomocí učení ze zkušeností si každý individuálně vytváří hypotézy o budoucím vývoji trhu. Na základě těchto hypotéz teprve tvoří svoje očekávání, a tedy i poptávkovou křivku.

Jak modelujeme ve výpočetním modelu agenty? Používáme k tomu variaci na produkční systémy. Každý agent udržuje množinu pravidel typu „podmínka \Rightarrow odhad“, kde podmínka symbolicky reprezentuje aktuální stav a minulý vývoj trhu, odhad určuje odhad budoucího vývoje cen akcií. Pro každé z těchto pravidel agent počítá jeho úspěšnost (jak moc přesný byl odhad v minulosti). V každém kroku agent vybere pravidla, jejichž podmínka splňuje aktuální stav trhu, a z těchto pravidel vybere nejúspěšnější. Pomocí nejúspěšnějšího pravidla agent vypočítá svůj odhad budoucího vývoje cen akcií a stanoví svoji poptávkovou křivku.

Díky přepočítávání úspěšnosti pravidel se agenti postupně učí ze zkušeností. Kromě tohoto učení dochází ještě k vývoji nových pravidel pomocí genetického algoritmu – jednou za čas agent zahodí neúspěšná pravidla a vytvoří nová rekombinací a mutací stávajících.

Pro ilustraci uvedme příklad konkrétního nastavení. Podmínka v pravidlech rozhoduje nad řetězcem 12 informací o stavu trhu (podmínka může specifikovat, že daná informace má nastat, nemá nastat nebo je to jedno). Použité informace lze rozdělit na dva typy: „fundamentální“ informace, např. zda hodnota dividend je větší než cena akcií \times úroková míra, „technické“ informace, např. zda aktuální cena je vyšší než průměr za posledních deset kol. Odhad je lineární kombinací ceny akcií a hodnoty dividend (odhad tedy sestává ze dvou parametrů).

Analýza simulací trhu s tímto nastavením vykazuje dva režimy fungování. První režim odpovídá pomalému učení, kdy dochází k malé frekvenci výměny pravidel po-

mocí genetického algoritmu. V tomto případě směřuje chování k rovnováze, cena akcií blízce odpovídá teoretickému deduktivní řešení, míra obchodování je nízká, nedochází ke spekulacím. Agenti používají k rozhodování téměř výlučně fundamentální informace. Druhý režim odpovídá rychlému učení, kdy dochází k velké frekvenci výměny pravidel pomocí genetického algoritmu. Dostáváme dynamické komplexní chování, agenti hodně obchodují, dochází ke spekulacím, sledování trendů, krachům. Agenti v tomto režimu hojně používají i technické informace o stavu trhu.

Popsaný model je jednoduchý a ukazuje především základní principy, které můžeme využít pro modelování trhu s induktivně uvažujícími agenty. Pomocí dalších rozšíření modelu však již můžeme studovat specifické problémy.

Souvislosti: Zmíněný model umělého trhu se nazývá „Santa Fe Artificial Stock Market“ a zavedl jej Arthur et al. (1997). Výpočetní model trhu funguje na velmi podobných principech jako model El Faron baru, který je uveden v kapitole 8.2.

13.3 Umělé společnosti

Věda se zabývá pozorováním světa okolo nás a snahou vysvětlit pozorovaná chování. Jak se pozná dobré vysvětlení? Vědecká teorie musí být falzifikovatelná – musí dělat předpovědi, které lze, alespoň hypoteticky, vyvrátit. Tak třeba teorie, že blesky jsou způsobeny tím, že bůh Thor má zrovna špatnou náladu, vědecká není, protože ji nelze nijak vyvrátit (kdybyste ovšem teorii doplnili o zaručený návod, jak potěšit či naštvat Thora, už by to byla seriózní, i když nepřilíš nadějná věda). Kritérium falzifikace funguje dobře v přírodních vědách, kde je většinou možné platnost teorií experimentálně ověřovat. Ovšem v sociálních vědách je to daleko komplikovanější. Psychologické experimenty na jedincích jsou ještě proveditelné (kromě případů, kdy to není etické, což je, přiznejme si, většina případů, které by nás *opravdu* zajímaly). Ale kdo vám půjčí jednu menší civilizaci, abyste mohli provést experiment na otestování své sociologické teorie? Formuláře grantových agentur většinou na pořízení experimentální civilizace nemají kolonku a jen málokdo má to štěstí, že má za přátele revolucionáře, kteří zrovna ovládli čtvrtinu světa a jsou ochotni poskytnout několik desetiletí na otestování teorie sociálního pořádku.

Důsledkem této obtížné falzifikovatelnosti je, že v sociálních vědách daleko častěji než ve vědách přírodních vedle sebe existuje současně několik nekompatibilních teorií. Co s tím? Jak tedy porovnávat různá vysvětlení sociálních jevů? Joshua Epstein, jeden z průkopníků modelování s agenty v sociálních vědách, nabízí zajímavé kritérium: „Pokud to neumíš vypěstovat, pak to neumíš vysvětlit.“ Pod pojmem vypěstovat rozumí namodelovat pomocí agentů, přesněji řečeno vytvořit model, který demonstruje „jak mohou lokální interakce autonomních, heterogenních, omezeně racionálních agentů generovat dané makroskopické chování?“ Modely, pomocí kterých se pěstuje chování sociálních systémů, nazývá Epstein umělé společnosti.

Povšimněme si, že uvedené kritérium je implikací. Pokud neumíme převést naše slovní vysvětlení na generativní model, pak to znamená, že naše vysvětlení je nedostatečné. Na druhou stranu ovšem schopnost reprodukovat chování pomocí modelu ještě rozhodně neznamená, že umíme chování vysvětlit. Může se třeba stát, že máme dva modely pro stejné chování a každý jej generuje pomocí jiných pravidel. Co pak? Pak máme alespoň vodítko, čím se zabývat dále. V čem spočívá rozdíl mezi modely? Jaká pozorování či experimenty by mohly předpoklady modelů vyvrátit?

Souvislosti: Obecný úvod do modelování v sociálních vědách podává například Epstein a Axtell (1996), Gilbert a Troitzsch (2005) nebo Gilbert (2008). Epstein (2006) se zaměřuje na modelování s agenty a kromě stručného metodického úvodu, ve kterém rozebírá výše zmíněné kritérium, poskytuje také přehled několika případových studií, mimo jiné kulturu Anasazi a model povstání, které zde stručně popíšeme. Zajímavé případové studie uvádí také Axelrod (1997a).


Povstání

Příkladem jednoduchého modelu umělé společnosti je model povstání, konkrétně model decentralizovaného povstání proti centrální autoritě (Epstein, 2006). Předpokládáme, že potenciální povstalci nejsou nijak systematicky organizováni a že se pouze každý za sebe individuálně rozhodují, zda se k povstání připojí nebo ne. Cílem modelu je zachytit dynamiku povstání, nikoliv jeho podstatu. Model má tedy vnější parametry popisující vztah lidí k autoritě, dynamiku těchto parametrů nemodelujeme. Jde o globální parametr udávající vnímanou legitimitu režimu a dále lokální parametry, které specifikují pro každého agenta útrapy (jak moc trpí), rozhořčení (dáno součinem nelegitimity a útrap) a obavu riskovat.

Model sestává z dvou typů agentů: občanů a policistů. Všichni agenti se pohybují po pravidelné mřížce, mají omezený výhled a jejich pohyb je náhodný. Agenti-občané se v každém kroku rozhodují, zda se stanou aktivními povstalci. Rozhodnutí se odvíjí od počtu policistů a aktivních povstalců ve výhledu. Na základě těchto hodnot agent odhadne pravděpodobnost zatčení v případě, že se přidá k povstání: čím víc policistů v okolí, tím větší pravděpodobnost zatčení, čím víc povstalců v okolí, tím menší pravděpodobnost zatčení. Odhadnutá pravděpodobnost se dále zkombinuje s rozhořčením agenta a jeho obavou riskovat – celkově tvoří kritérium pro rozhodnutí jeden mírně komplikovaný matematický vzorec.

Agenti-policisté se nikdy nevzbouří. Pokud mají ve výhledu aktivního povstalice, pošlou jej do vězení (mimo plochu). Povstalec stráví ve vězení dobu, která je náhodně zvolena z předepsaného intervalu.

Pro dynamiku modelu je klíčová interakce zpětných vazeb. Pozitivní zpětná vazba žene povstání vpřed: čím víc občanů se bouří, tím nižší je odhadovaná pravděpodobnost zatčení a tím víc občanů se bouří. Negativní zpětná vazba povstání brzdí: čím víc občanů se bouří, tím víc občanů skončí ve vězení. Pro interakci těchto zpětných vazeb je důležitá heterogenita agentů. Každý občan má jiné útrapy a jinou obavu riskovat, díky čemuž se občané bouří postupně.



Obr. 13.3: Model povstání: chování modelu při průběžné a skokové změně legitimacy režimu (Epstein, 2006).

Typický průběh simulace vypadá následovně. Nejdříve se nikdo nebouří. Pak na místě, kde je zrovna náhodou málo policistů, začne několik občanů protestovat, povstání se rychle rozšíří a přidá se k němu hodně občanů, policisté je postupně všechny pozatýkají a zbudou jen ti, co mají malé útrapy nebo velkou obavu riskovat, a je klid. Pak se postupně vracejí povstalci z vězení, až se opět nakumuluje dostatečné množství potenciálních povstalců a povstání propukne znovu.

Ačkoliv v modelu hraje důležitou roli náhoda (náhodný pohyb agentů), vykazuje přesto řadu pravidelností na makroskopické úrovni, např. v celkových počtech povstalců nebo v časových odstupech mezi dvěma po sobě jdoucími povstáními. Jde tedy o určitou formu emergentního chování, kterým jsme se zabývali u přírodních decentralizovaných systémů.

Podívejme se na experimenty s modelem. Co se stane, když se změní vnímaná legitimacy režimu? Záleží na tom, zda ke změně dojde postupně, nebo naráz (obr. 13.3). Pokud se legitimacy režimu snižuje postupně, tak se občané bouří po jednotlivcích, jsou hned zatýkáni a nedojde k velkému povstání. Pokud se legitimacy režimu sníží skokově (jeden velký skandál), tak dojde k velkému povstání. Co se stane, když postupně ubývá policistů? Nejprve se neděje nic, ale při překročení určité meze najednou propukne velké povstání. Na základě modelu tedy můžeme doporučit revolucionářům, aby neupozorňovali na chyby režimu postupně, ale aby si šetřili materiál na jeden velký skandál. Vlády zase můžeme varovat, aby byly obzvláště obezřetné při pozvolném uvolňování kontroly. Tento model je velice jednoduchý a abstraktní, ale jeho dynamika je přesto zajímavá, občas překvapující a ilustruje několik principů, které lze pozorovat v realitě.

Kultura Anasazi

V sociologii je provádění experimentů náročné, ovšem v takové archeologii je už úplně nemožné. Posuzování různých hypotéz je v archeologii tedy obzvláště obtížné. Modelování pomocí agentů nám dává alespoň náhražku za experimenty – umožňuje

nám přehrát si zjednodušeně minulost a alespoň na umělé společnosti experimentálně vyzkoušet věrohodnost našich hypotéz.

Příkladem studie, která využívá modelování pomocí agentů v archeologii, je projekt Artificial Anasazi, který se zabývá severoamerickou kulturou Anasazi (Epstein, 2006). Tato kultura žila v Arizoně, konkrétně v údolí Long House Valley na rozloze asi 100 km². Hlavní rozkvět spadal do let 800–1300, po roce 1300 bylo údolí opuštěno.

Archeologické studium této kultury je na velmi dobré úrovni. V údolí jsou suché klimatické podmínky a po zmizení kultury Anasazi zde nebyl téměř žádný civilizační ruch. Díky těmto okolnostem zůstalo celé údolí dobře zachováno a vědci dokázali velmi dobře reprodukovat přírodní podmínky a vývoj kultury Anasazi. Ví se například, jaká byla v kterých letech úrodnost nebo jak velké bylo osídlení a kde bylo rozmístěno. I přes detailní znalost podmínek zůstává jedna klíčová otázka nezodpovězena. Proč bylo po roce 1300 údolí opuštěno? Bylo to způsobeno environmentálními vlivy, nebo něčím jiným (např. válkou)?

Cílem projektu Artificial Anasazi je zachytit hypotézy o vývoji kultury a pokusit se odpovědět na otázku, zda změna environmentálních podmínek je dostatečným vysvětlením opouštění údolí. Oproti většině modelů, se kterými jsme se doposud setkali, v tomto případě jsou k dispozici konkrétní data a cílem modelování je zkonstruovat model, který bude těmto datům co nejbližší.

Projekt Artificial Anasazi je založen na modelech s agenty a základní principy modelu jsou obdobné jako u ostatních modelů s agenty, které jsme zatím popsali. Agenti se pohybují po dvourozměrné ploše. Políčka mají přiřazeny atributy, jako je například úrodnost a dostupnost vody, tyto atributy se v čase mění a odpovídají reálným datům. Agenti představují celé usedlosti (nikoliv jednotlivce) a řídí se jednoduchými pravidly (zde uvedená pravidla představují základní verzi modelu, kterou autoři dále rozšiřují):

- Pěstování a konzumace jídla. Množství vypěstovaného jídla závisí na úrodnosti okolních polí, konzumace je fixní.
- Rozdělení usedlosti (sňatek).
- Stěhování. Když se usedlost nemůže uživit nebo když dojde ke vzniku nové usedlosti, nastává stěhování. Při stěhování se zohledňuje úrodnost půdy, dostupnost vody a přítomnost cizích usedlostí na okolních polích.

Autoři nakalibrovali parametry modelu tak, aby odpovídaly dostupným historickým datům. I s uvedenými jednoduchými pravidly se jim podařilo do značné míry reprodukovat vývoj reálného osídlení, a to včetně rozmístění usedlostí po údolí.

Co studium umělé kultury přineslo? Autoři provedli s modelem důkladné analýzy a ve všech simulacích dochází po simulovaném roce 1300 k výraznému poklesu populace, nikoliv však k jejímu úplnému vymizení. To znamená, že podle modelu není změna environmentálních podmínek dostatečným vysvětlením pro vymizení celé kultury Anasazi. Alternativní vysvětlení nám model sám o sobě neposkytuje – nyní je nutné, aby archeologové dál zkoumali dostupné podklady a snažili se přijít s novými hypotézami. Ty pak bude možné opět prozkoumat s využitím umělé společnosti Artificial Anasazi.

13.4 Shrnutí

- V ekonomii se modely používají již dlouho. Většinou jde o matematické modely vycházející z dominance negativních zpětných vazeb a předpokladu racionality. Řešení těchto modelů se zaměřuje na hledání ekvilibria.
- Jakmile chování systému dominuje pozitivní zpětná vazba (zákon rostoucích výnosů) nebo chceme zachytit induktivní myšlení agentů, vyplatí se použít výpočetní modely.
- Induktivní myšlení agentů na trhu můžeme zachytit pomocí produkčních systémů. Model umělého trhu s induktivně uvažujícími agenty může zachytit takové jevy, jako jsou spekulace a krachy.
- Jak poznáme dobré vysvětlení sociálního jevu? Jako možné kritérium můžeme použít: „Pokud to neumíš vypěstovat, pak to neumíš vysvětlit.“ Vypěstovat znamená vygenerovat pomocí výpočetního modelu (umělá společnost).
- Sociální jevy většinou modelujeme na abstraktní úrovni (viz příklad s modelem povstání), ale můžeme také vytvářet modely, jejichž cílem je reprodukovat konkrétní data (viz příklad kultury Anasazi).

14 Spolupráce a soutěžení

M: Mám nový námět do seminárky – Problém králíčího palouku. Je to modelová situace, která jasně vystihuje problémy králíčího soužití. Představme si les, ve kterém je jeden palouk s chutnou trávou. Králíci se pasou a množí se. Každý chce mít co nejvíc potomků. Králíků přibývá. A tak se stane, že spasou skoro všechnu travu na palouku, tráva nestíhá dorůstat a přichází kolaps a většina králíků vymírá. Kdyby byli jen trochu skromnější, mohlo jich přežít docela hodně. Dívej, tady jsem to propočítal pro konkrétní hodnoty.

S: Vidíš, opět jsi narazil na společnou vlastnost lidí a králíků. Tvůj problém je velmi podobný Problému obecní pastviny, což je modelová situace vystihující problémy soužití lidí, kteří sdílejí společný zdroj. Také v tomto případě vede prosazování sobeckých zájmů ke kolapsu.

M: No, co naděláš. Ve světě, který je hnaný kupředu slepou evolucí založenou na výběru nejsilnějších, není pro spolupráci místo.

S: Tak to se mylíš. Spolupráce může být výhodná i pro sobecké jedince. A může se dokonce vyvinout i evolučně.

M: To se mi moc nezdá. Vždyť sobec si vždycky urve víc než ten, kdo pomáhá ostatním, a tedy sobec je vždy silnější, má víc potomků a časem v evolučním závodě zvítězí.

S: Díváš se na evoluci příliš zjednodušeně. Dívej, zkusím ti to ukázat na jednom známém příkladě. Že jsi to ty, řekněme tomu Králíkové dilema. Představ si dva králíky, které honí liška. Každý králík se musí rozhodnout: buď se zkusí schovat, nebo bude utíkat dál. Pokud budou oba králíci utíkat dál, mají solidní šanci, že liška ani jednoho z nich nechytí. Jak praví přísloví: „Kdo honí dva králíky, nechytí žádného.“ Když se jeden z králíků schová a druhý poběží dál, liška bude pronásledovat toho, co utíká, a je dost pravděpodobné, že jej chytne, zatímco ten schovaný v bezpečí přežije. Když se však schovají oba dva, liška bude čenichat okolo a nejspíš jednoho z nich časem najde. Králík má tedy dilema: utíkat, nebo se schovat? Útěk představuje spolupráci s druhým králíkem, skrývání představuje sobecký zájem.

M: Jestli to dobře chápu, můžu si jejich možnosti vyjádřit tabulkou – pokud se dobře pamatuju, říká se tomu model teorie her. Když se na tu tabulku dobře podíváš, je jasné, že ačkoliv globálně by byla výhodnější spolupráce, převládá sobecký zájem.

S: Pamatuješ si to správně – jde opravdu o model teorie her, a pokud uvažujeme jen jedno izolované rozhodnutí, opravdu převáží sobecký zájem. Jenže teď si představ, že taková situace nastává opakovaně a v celé populaci králíků. Věci hned začnou být složitější, a pokud chceš situaci dobře porozumět, přijdou na řadu kromě teorie her třeba i genetické algoritmy.

14.1 Dilema vězně

V této kapitole se zabýváme především variacemi na následující otázku: Může se udržet (vyvinout) spolupráce ve skupině soutěživých egoistických jedinců? Ke studiu této otázky využijeme známý problém Dilema vězně a jeho rozšíření.

Motivace

Začneme tradiční motivací, která ostatně dala modelu jméno. Dva zločinci spáchali společně těžký zločin. Byli dopadeni a jsou drženi v oddělených celách. Policie však proti nim nemá dostatek důkazů, a tak vyšetřovatel přijde za nimi a dá každému z nich následující nabídku:

- Když budeš zapírat, stejně půjdeš do vězení, protože máme důkazy na některé tvoje menší zločiny.
- Pokud však udáš toho druhého, my to už zařídíme, abys ty vyšel volný, protože toho druhého budeme moci odsoudit a vykázat tak úspěšnou činnost na vedení.

Oběma vězňům je jasné, že kolega dostal úplně stejnou nabídku. Každý je v jiné cele a nemohou se domluvit, takže hrozí, že pokud se udají navzájem, tak půjdou do vězení oba dva. Tabulkou můžeme situaci vyjádřit následovně:

já \ on	zapírat	udat
zapírat	1 rok	20 let
udat	volný	5 let

Jak se má zločinec nyní rozhodnout? Celkově pojata nejvýhodnější by bylo, kdyby oba dva zapírali (vzájemně spolupracovali), ale současně mají oba dva motiv toho druhého udat (zradit). Jde o zdánlivě jednoduchou modelovou situaci, ovšem jak ukážeme, model skýtá mnoho prostoru pro zajímavé analýzy, zvláště pokud základní model mírně rozšíříme. Navíc přestože jde o jednoduchou situaci, má celou řadu zajímavých aplikací.

Typickou aplikací, používanou především v době studené války, jsou závody ve zbrojení. Dvě velmoci se rozhodují, zda zbrojit hodně, či málo. Levnější samozřejmě je zbrojit málo, ale hrozí, že soupeř bude zbrojit hodně, což znamená velmi nevýhodnou situaci. Když však obě strany zbrojí hodně, tak si příliš nepomohou. Pokud rozepíšeme tabulku možností, zjistíme, že situace je zcela analogická Dilematu vězně. Stejný princip můžeme nalézt například u celní politiky (uvalit, nebo neuvalit clo),

nákladů na reklamu (investovat hodně, nebo málo do reklamy) nebo u analýzy možností cyklistické dvojice v úniku (střídat na čele, nebo se vést v závětrí).

V případě, že model zobecníme na více než dva hráče, dostáváme další aplikace, například situaci s volně loženými placenými novinami. Spolupráce odpovídá tomu, že si vezmu noviny a vhodím příslušný obnos do kasičky. Zrada odpovídá tomu, že si vezmu noviny a nezaplatím. Když většina zradí a nezaplatí, provozovatel noviny stáhne a výsledná situace bude horší pro všechny, protože budou muset nejen platit, ale navíc i chodit do obchodu.

Jiná obecná situace je známa pod názvem Tragédie obecní pastviny (Hardin, 1968). Na společné pastvině pase ovce několik farmářů. Pastvina má omezenou kapacitu – pokud se na ní bude pást více ovcí, než je její kapacita, dojde k přepásání, pastvina začne degradovat a nakonec užíví méně ovcí než na začátku. Nejvýhodnější je tedy, když všichni drží velikost svých stád v přiměřených mezích. Současně však má každý farmář tendenci přidat si nějakou tu ovci navíc. Tato situace poměrně přesně odpovídá mnohým environmentálním problémům, u kterých „pastvina“ představuje sdílený zdroj (např. vzduch, moře).

Souvislosti: Model Tragédie obecní pastviny je jedním z cvičení navrhovaných v příloze D.

Dilemata

Nyní hru definujeme formálně. Obecně je tento typ hry popsán tabulkou, která pro každou kombinaci rozhodnutí udává dvě hodnoty: zisk můj a zisk oponenta.

já\on	spolupráce	zrada
spolupráce	SS; SS	SZ; ZS
zrada	ZS; SZ	ZZ; ZZ

Hodnoty (SS, SZ, ZS, ZZ) parametrizují hru a podle jejich hodnot dostáváme různá dilemata. Dilema vězně odpovídá parametrům splňujícím $ZS > SS > ZZ > SZ$ (občas se navíc vyžaduje, aby $SS > \frac{ZS+SZ}{2}$). Pro ilustraci zmiňme i další varianty vedoucí k zajímavým dilematům. Hru Kuře dostáváme pro parametry splňující $ZS > SS > SZ > ZZ$. Motivace popisující tuto variantu je následující: dva machři jedou v autech přímo proti sobě, ten, kdo uhne, je kuře (zbabělec), ovšem pokud neuhne ani jeden, tak se srazí. Další varianta je Lov na jelena, která nastává pro parametry $SS > ZS > ZZ > SZ$. Rozhodujeme se, zda jít lovit jelena (spolupráce), nebo zajíce (zrada). Jelen je větší odměna, ale jeden ho sám neuloví. Zajíc je menší úlovek, ale je to jistota, protože jej zvládne ulovit každý sám.

Zde se budeme dále zabývat pouze variantou Dilema vězně, a to konkrétně následujícími hodnotami parametrů:

já\on	spolupráce	zrada
spolupráce	3; 3	0; 5
zrada	5; 0	1; 1

Konkrétní hodnoty však nejsou pro většinu analýz nijak důležité. Dokonce není ani nezbytně nutné, aby hodnoty byly absolutní (stačí relativní uspořádání), a zisky různých hráčů nemusí být symetrické ani přímo srovnatelné. Velice důležité však je, že jde o hru s nenulovým součtem, přestože lidé o ní často uvažují, jako by to byla hra s nulovým součtem. Z tohoto důvodu v následujícím popisu nepoužíváme výraz „soupeř“, ale vhodnější „partner“ nebo „druhý hráč“.

Základní analýza

Analyzujeme situaci z pohledu jednoho z hráčů. Pokud druhý hráč spolupracuje, je výhodnější zradit (zisk 5 bodů) než spolupracovat (zisk 3 body). Pokud druhý hráč zradí, je výhodnější zradit (zisk 1 bod) než spolupracovat (zisk 0 bodů). Ať tedy druhý hráč udělá cokoliv, je výhodnější zradit. Z pohledu egoistických hráčů tedy nejde o žádné dilema, protože existuje stabilní, optimální strategie, a tou je zrada. Pokud hrajeme se stejným partnerem na více kol a počet kol je dopředu znám, pak stále funguje podobný styl analýzy. V tomto případě musíme navíc argumentovat zpětnou indukci – nejdříve dokážeme výhodnost zrady v posledním kole, poté v předposledním a tak dále až po první kolo. Opět zjišťujeme, že je jednoznačně výhodné zradit.

Kdybychom studovali, jak se v této situaci rozhodují lidé, zjistili bychom, že už v těchto základních situacích se lidé rozhodují složitěji, než naznačuje uvedená deduktivní analýza. I když po analytické stránce hra dilema neobsahuje, po stránce sociální tam rozhodně je: přece když oba zradíme, tak na tom budeme hůř, než kdybychom oba spolupracovali. Nemluvě o tom, že pohotově uvažovat pomocí zpětné indukce zvládá zanedbatelné procento populace. Takže i základní varianta hry poskytuje dostatek prostoru pro zkoumání, především po psychologické stránce. My zůstaneme u plně egoistických, racionálních hráčů, jen jim situaci trochu zkomplikujeme.

14.2 Turnaje počítačových strategií

I nadále budeme používat základní variantu hry, pouze necháme hráče hrát postupně s více různými partnery a výsledky nakonec sečteme. V tomto případě už neplatí, že je jednoznačně nejvýhodnější zradit. Když já budu ve svých zápasech hrát neustále samé zrady, partneři mi to nejspíš budou oplácet a můj průměrný bodový zisk bude přibližně 1 bod. Pokud však jiní hráči ve svých zápasech zvládnou dospět k vzájemné spolupráci, jejich průměrný bodový zisk se může pohybovat okolo 3 bodů, a budou tedy lepší než já.

Jak se zachovat v této situaci? Jaká je nejlepší strategie? Při hledání odpovědi na tyto otázky můžeme využít počítačovou simulaci. V 80. letech uspořádal Robert Axelrod turnaje ve vícekolové variantě, ve které se hráč utkává se všemi partnery. V turnajích proti sobě hrály počítačové strategie. Na turnaje se můžeme dívat jako

na ABM model, ve kterém strategie představují pravidla jednotlivých heterogenních agentů.

Strategie

Strategie je počítačový program, který na vstup dostane dosavadní historii zápasu a podle ní se rozhodne, jaký má být další tah. Příklady jednoduchých strategií:

- hraj náhodně,
- vždy zrad,
- vždy spolupracuj,
- začni spoluprací a spolupracuj tak dlouho, dokud partner nezradí, jakmile partner jednou zradí, tak až do konce hry zrazuj,
- začni spoluprací a pak hraj vždy to, co hrál partner v posledním tahu.

Poslední zmiňovanou strategií, která je i přes svou jednoduchost velmi významná, dále označujeme TFT (z anglického „tit for tat“, což se do češtiny překládá jako „oko za oko“ nebo „půjčka za oplátku“).

Uvedené jednoduché strategie využívají pro rozhodnutí jen velmi málo z dosavadní historie zápasu. Lze navrhovat i výrazně složitější strategie. Příkladem takové složitější strategie je pravděpodobnostní odhad soupeře – strategie se snaží zjistit, jak moc soupeř reaguje na spolupráci či zradu. Pokud reaguje hodně (jako například TFT), je výhodnější spolupracovat, pokud reaguje málo (jako například náhodná strategie), je lepší zrazovat.


První turnaj

Axelrod vyzval vědce z různých disciplín, které dilema vězně používají, aby mu zaslali strategie. Celkem obdržel 14 strategií od matematiků, ekonomů, psychologů a politologů. Zasláné strategie pak hrály turnaj stylem každý s každým, přičemž se používala výše uvedená tabulka hodnot a hrálo se na 200 kol. Kromě zasláných strategií se turnaje účastnila i náhodná strategie.

Výsledky turnaje byly překvapivé. Přestože se turnaje zúčastnily rozličné sofistikované strategie, vyhrála ta nejjednodušší ze všech – strategie TFT. Celkově se lépe umístily „hodné“ strategie, což jsou strategie, které nikdy nezradí jako první. Většina účastníků se strategií byla variací na TFT, ale snažily se být „drsnější“, to znamená, že občas zradily, i když soupeř spolupracoval. Při daném složení soutěžících strategií bylo naopak potřeba být spíše ještě „hodnější“ než TFT. Například strategie TF2T („tit for two tat“, „oko za dvě oči“), která zradí, až když druhý hráč zradí dvakrát za sebou, by v turnaji zvítězila, kdyby byla zaslána.

Druhý turnaj a ekologické rozšíření

O pár let později uspořádal Axelrod druhý turnaj, který byl speciálně zaměřen na porážení TFT. K účasti na tomto turnaji vyzval amatéry i profesionály z celého světa, zúčastnilo se celkem 63 strategií. Účastníci znali výsledky i podrobné analýzy prvního



Obr. 14.1: Výsledky ekologického rozšíření turnaje (podle Axelrod, 1985). Čísla strategií odpovídají pořadí strategií v druhém turnaji. TFT je číslo 1.

turnaje. Turnaj probíhal stejným stylem jako turnaj první. Přestože si účastníci odnesli mnohá poučení z těchto analýz, hlavní výsledky byly velmi podobné. Vyhrála opět strategie TFT, hodné strategie dopadly lépe než ty drsné. Složení strategií však bylo o dost jiné než v prvním turnaji, takže například TF2T by v tomto turnaji úspěšná nebyla, protože mezi soutěžícími strategiemi byly takové, které dokázaly přílišnou benevolenci TF2T zneužít.

Jak ukazuje příklad strategie TF2T, která jednou mohla zvítězit, podruhé by však dopadla špatně, úspěch strategií závisí na tom, s kým se utkávají. Proto Axelrod uspořádal další turnaj – ekologické rozšíření druhého turnaje. Vzal strategie, které byly zaslány pro druhý turnaj, a vyrobil jejich imaginární populace. Tyto populace spolu sehrály jedno kolo turnaje a podle úspěšnosti se množily nebo vymíraly. Takto nechal Axelrod sehrát opakovaně mnoho generací a sledoval vývoj zastoupení jednotlivých strategií.

Obr. 14.1 znázorňuje výsledky ekologického turnaje. Strategie TFT si udržela své první místo a vyhrála i v ekologickém turnaji. Za povšimnutí stojí strategie číslo 8 – jde o sofistikovanou „zlou“ strategii, která se snaží pomocí zrad zneužít soupeře. Na začátku se jí daří, protože se přizívuje na naivních a neúspěšných strategiích. Avšak tyto naivní strategie posléze vymřou a zůstanou pouze strategie, které jsou hodné, takže vzájemně nebojují a získávají hodně bodů, a současně nejsou naivní, takže se od zlé strategie nenechají vykořisťovat. V této populaci už strategie číslo 8

není úspěšná a pomalu vymírá. V populaci zůstávají jen hodné strategie a populace se tak stabilizují, protože všichni získávají stejný počet bodů.

Evoluční rozšíření

Uvedené výsledky naznačují, že spolupráce může být výhodná i v čistě soutěživém prostředí. Výsledky byly získány v objektivních, soutěživých podmínkách pomocí čistě chladnokrevných počítačových strategií. Nicméně však soutěžící strategie byly napsány lidmi. Nabízí se tedy otázka, jak moc jsou výsledky ovlivněny tímto faktem. Není dominance spolupracujících strategií způsobena tím, že strategie navrhli lidé, kteří očekávali, že ostatní soutěžící strategie budou fungovat „lidským“ způsobem?

Abyste mohl odpovědět na tuto otázku, uspořádal Axelrod evoluční turnaj strategií, ve kterém proti sobě soutěžily strategie vyvíjené genetickým algoritmem. Pro účely genetického algoritmu je potřeba strategii reprezentovat konečným řetězcem. Proto byly pro evoluční turnaj použity pouze strategie, které ve svých rozhodnutích zohledňují jenom posledních k kol hry. Například pro $k = 1$ (strategie si pamatuje pouze výsledek posledního kola) potřebuje k reprezentaci strategie řetězec 5 znaků:

1. Tah v prvním kole.
2. Co dělat, když jsme minule oba spolupracovali.
3. Co dělat, když jsem minule já spolupracoval a partner zradil.
4. Co dělat, když jsem minule já zradil a partner spolupracoval.
5. Co dělat, když jsme minule oba zradili.

V tomto kódování je strategie, která vždy spolupracuje, reprezentována řetězcem „SSSSS“, strategie TFT je reprezentována řetězcem „SSZSZ“. Na takto reprezentovaných strategiích už můžeme snadno provádět křížení a mutace. Zdatnost získáme jako průměrný bodový zisk v zápase s ostatními strategiemi v populaci.

Axelrod ve svém turnaji použil strategie, které zohledňují poslední tři tahy. Průběh evolučního turnaje byl zhruba následující. Turnaj začíná s náhodnými strategiemi a bodový zisk je okolo 1,7 bodu na hru. Během prvních kol hry jsou úspěšné strategie, které hodně zrazují. Ty se v populaci rozšíří, čímž pádem průměrný bodový zisk poklesne skoro až k 1 bodu na hru (což odpovídá neustálé oboustranné zradě). Zhruba od desáté generace se však začnou objevovat strategie, které dokáží opětovat spolupráci a přitom se nenechají zneužít zlými strategiemi. Tyto strategie se v populaci následně rozšíří a průměrný bodový zisk v populaci stoupne až k 2,5 bodu za zápas.

Pomocí genetického algoritmu nedostaneme přesně TFT, nicméně strategie, které se vyvinou, mají základní charakteristiky TFT: na začátku spolupracují, oplácí zradu, odpouští. Úspěch těchto strategií v evolučním turnaji znamená, že dominance principů, na kterých je TFT založena, není způsobena lidskými očekáváními či kulturními hodnotami, ale jejich principiální výhodností.

Poučení

Jak chcete, aby lidé jednali s vámi, tak jedněte vy s nimi. (Lukáš 6:31)

Z výsledků je zjevné, že TFT je úspěšná strategie. Je však třeba podotknout, že úspěch vždy záleží na prostředí. Pro tuto hru (a obecněji pro situace, které tato hra modeluje) neexistuje žádná nejlepší strategie. Například v situaci, kdy všichni ostatní pouze zrazují, nelze dělat nic lepšího než také zrazovat. Výjimečnost strategie TFT spočívá v její robustnosti – funguje dobře v mnoha prostředích.

Pokusme se poučit z úspěchu strategie TFT a odvodit z průběhu počítačových turnajů rady pro hráče ve skutečných situacích:

- **Nebud' závistivý.** Uvědom si, že Dilema vězně není hra s nulovým součtem. Co je dobré pro partnera, může být dobré i pro tebe. Všimni si například, že strategie TFT v dílčí hře nikdy nemůže získat více bodů než druhý hráč.
- **Bud' hodný.** Nemá smysl být ten první, kdo zradí, protože zrada má odezvy a v konečném důsledku na to doplatíš sám.
- **Oplácej.** Je potřeba oplácet jak zradu, tak spolupráci. Nesmíme se nechat druhým hráčem využívat, ale současně je potřeba umět odpouštět.
- **Nesnaž se být příliš chytrý (Istivý, neprůhledný).** Na rozdíl od her s nulovým součtem může být v případě hry Dilema vězně výhodné, když druhý hráč ví, co od tebe může čekat. Pokud se striktně držíš strategie TFT, je dobré, když o tom ostatní ví.

Za pozornost stojí, že tato poučení, která jsme odvodili z dlouhodobých zájmů sobeckých jedinců, se docela dobře shodují s klasickými morálními pravidly odvozovanými z „vyšších principů“ (náboženství, etika, filozofie).

Na závěr musíme podotknout, že existuje mnoho dalších studií, které se zabývají problémem Dilematu vězně a jež zde uvedené pozorování dále rozšiřují. Důležité je například rozšíření o náhodu – šum v prostředí, jehož vlivem se zamýšlená spolupráce může změnit na zradu. V takovém prostředí již klasické TFT nefunguje dobře, protože náhodná nezamýšlená zrada může vést k dlouhému řetězci vzájemných oplat. I v těchto případech se však základní principy TFT uplatní, jen je potřeba je vhodně upravit. Úspěšné jsou v tomto kontextu např. „velkorysé TFT“, které s malou pravděpodobností spolupracuje, i když partner v minulém kole zradil, nebo „kající TFT“, které kontroluje, zda v minulosti došlo k chybě vlivem šumu, a pokud ano, tak se „omluví“ bezpodmínečnou spoluprací.

Souvislosti: Výklad čerpá z výzkumů Roberta Axelroda, které jsou shrnuty v jeho dvou knihách (Axelrod, 1985, 1997). Kromě detailnějšího rozboru zde nastíněných výsledků je v těchto knihách uvedeno také mnoho konkrétních příkladů.

14.3 Modelování vzniku norem

Nyní se podíváme na další výzkum od Roberta Axelroda, ve kterém se využívá variace hry Dilema vězně. Jde o problém vývoje norem ve společnosti. Co jsou to normy? Ve společnosti existuje norma, pokud jednotlivci většinou jednají jistým způsobem, a jsou potrestáni, pokud tímto způsobem nejednají. Příklady norem jsou: společenské normy, technické standardy (normy na úrovni firem), regulace ve zbrojení či ve vztahu k životnímu prostředí (normy na úrovni států). Normy mohou být také negativní, jako například otrokářství či kolonialismus.

V konečném stadiu bývají normy ustanoveny zákonem a jejich dodržování je vyvíháno určitou centrální autoritou. Vztah norem a zákonů však není úplně přímočarý. Například společenské normy jsou vesměs dodržovány, i když je žádné zákony nepokrývají. Naopak uzákonění ještě samo o sobě normu nevytvoří. Příkladem může být zákaz řízení po požití alkoholu, respektive s mobilním telefonem v ruce. Oboje je uzákoněno, první už se pomalu stává normou, druhé má k normě ještě hodně daleko.

Jak tedy normy vznikají? Kdo trestá porušování normy ve chvíli, kdy není centrálně hlídána? Ukážeme model, který se pokouší o vysvětlení vývoje norem pomocí evolučního modelu a simulace.

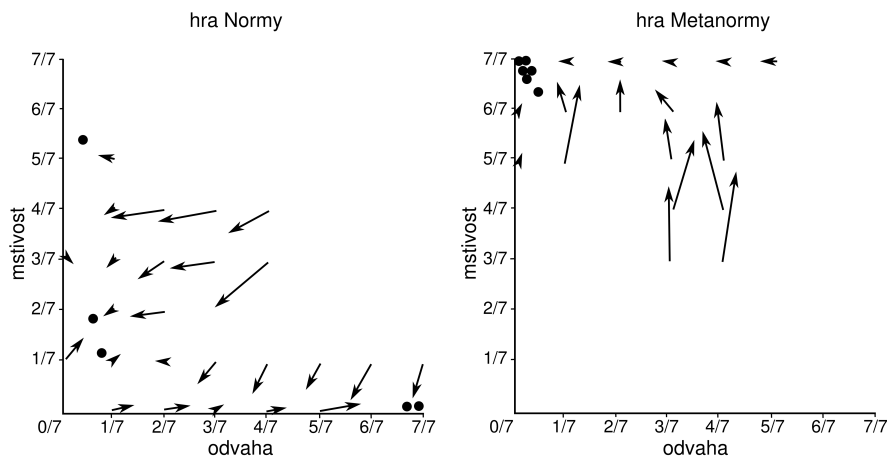
Hra Normy

Základem hry Normy je hra Dilema vězně rozšířená pro n hráčů. Základním tahem je spolupráce (dodržování normy), která má pro jednoduchost neutrální účinek (0 bodů). Každý hráč může zradit (porušit normu), za což získá odměnu (3 body), ovšem všichni ostatní tím přijdou ke ztrátě (-1 bod). Kdybychom nechali hru v této podobě, tak zde není prostor pro rozvoj spolupráce. Vývoj a udržení spolupráce u hry Dilema vězně je založen na zpětné vazbě – když zradím, tak se mi to v dalším kole vrátí. U rozšíření na více hráčů zpětná vazba není cílená – případná odplata je plošná a zasáhne nejen zrádce, ale všechny hráče – a je nedostatečně efektivní na rozvinutí spolupráce.

Hra Normy přidává možnost přímého potrestání. Řekněme, že hráč i zradí. Ostatní hráči jej s určitou pravděpodobností uvidí. Pokud hráč j vidí, že hráč i zradil, má možnost jej potrestat – v takovém případě hráč i dostane velký trest (-9 bodů) a hráč j dojde také ke ztrátě (-2 body), protože trestání jej stojí energii – jak jistě potvrdí kdokoli, kdo se ve svém okolí pokoušel šířit nějakou společensky prospěšnou normu.

Strategie hráče je v této hře dána dvěma parametry. Parametr „odvaha“ udává pravděpodobnost, že hráč bude podvádět, parametr „mstivost“ značí pravděpodobnost, že hráč potrestá podvádění, když jej uvidí. Pokud tyto parametry reprezentujeme jako bitové řetězce, můžeme pro simulaci evolučního vývoje hry snadno použít genetický algoritmus.

Axelrod se rozhodl pro následující nastavení: strategie je dvojice parametrů odvaha a mstivost, přičemž každý z nich je kódován 3 bity (tj. 8 možností pro každý parametr), populace má 20 jedinců, do další generace se množí podle zisku bodů,



Obr. 14.2: Dynamika her Normy a Metanormy (podle Axelrod, 1997a). V grafu jsou vynešeny zprůměrované hodnoty parametrů odvaha a mstivost v celé populaci. Na začátku simulace tedy začínáme zhruba uprostřed diagramu. Šipky znázorňují změnu průměrných hodnot parametrů v průběhu simulace, tečky značí konečný stav pěti spuštěných simulací.

mutace se vyskytují jen s malou pravděpodobností, spuštěno je 5 simulací o 100 generacích.

Obr. 14.2 zachycuje dynamiku a konečný stav hry. Jak je vidět z grafu, hra se vyvine vždy do jedné ze dvou konfigurací:

1. Norma převládá: odvaha je nízká, podvádí se jen výjimečně.
2. Norma se neujala: odvaha je velmi vysoká, mstivost nulová.

Metanormy

Axelrod ve své studii rozebírá možnosti, jak prosadit rozšíření normy. Jako jednu možnost studuje metanormy – možnost potrestat někoho, kdo viděl a nepotrestal. Axelrod jako příklad metanormy uvádí rasismus ve 30. letech v Americe. Když se dav zachoval nespravedlivě vůči černochovi a jeden z přihlížejících pronesl nesouhlasnou poznámku, tak byl zbit. Rasismus je zde normou, potrestání nesouhlasu s rasismem metanormou.

Hra Metanormy je oproti hře Normy rozšířena o následující pravidlo: pokud hráč k vidí, že hráč j viděl zradu hráče i a nepotrestal ji, pak hráč k může hráče j potrestat. Pro jednoduchost předpokládáme stejnou hodnotu parametru mstivost pro přímé trestání i pro meta-trestání. Simulace evolučního vývoje pak probíhá analogicky jako v předchozím případě. Obr. 14.2 ukazuje vývoj v této situaci – v tomto případě vždy rychle klesá odvaha a stoupá mstivost, tj. norma je ustanovena.

Další způsoby podpory norem jsou například: dominance jedné skupiny (například otrokářství), vnitřní změna hodnot neboli internalizace normy (například třídění odpadu kvůli přesvědčení o správnosti takového činnění), odstrašování, sociální tlak nebo reputace. I tyto další způsoby můžeme vyjádřit pomocí modelů, například dominanci pomocí dvou oddělených populací v modelu a internalizaci pomocí heterogenních agentů, kterým se individuálně mění tabulka bodového ohodnocení.

Souvislosti: Se šířením norem úzce souvisí Problém obecní pastviny, který je uveden mimo jiné jako námět na cvičení v příloze D.

14.4 Altruismus

Altruistické chování je takové, které přináší zisk nikoliv pro konajícího jedince, ale pro ostatní. Pro konajícího je takové jednání většinou dokonce nevýhodné (například skrze ztrátu času a energie). Existence altruistického chování se intuitivně zdá být v protikladu s evoluční teorií. Zdá se, že nositelé genů zapříčiňujících altruistické chování by měli mít menší zdatnost než sobci, kteří z altruistů mohou těžit, a altruisté by tak měli vymřít.

Vysvětlení evolučního vývoje altruistického chování není jednoduché a figuruje v něm několik principů. Zde si na dvou jednoduchých modelech ilustrujeme pouze dva dílčí principy: vliv podmínek prostředí a populační viskozity na šíření altruismu. Populační viskozita znamená omezené šíření populace v prostoru, což má za důsledek zvýšenou genetickou podobnost v lokálním okolí.

Buněčný automat


První model, který uvedeme, je pravděpodobnostní buněčný automat na pravidelné čtvercové mřížce (obr. 14.3). Každé pole mřížky může být prázdné nebo osídlené jedním ze dvou typů buněk: sobecká a altruistická. Model má dva parametry c, b . Parametr c udává „cenu altruismu“ (jak moc mě altruistické chování stojí), parametr b udává „zisk z altruismu souseda“ (jak moc mi pomůže altruistické chování mého souseda).

Zdatnost buňky určujeme na základě jejího okolí, přičemž jako okolí uvažujeme čtyři bezprostředně sousedící buňky plus buňku samotnou. Označme N_A počet altruistických buněk v tomto okolí, potom celková zdatnost buňky je:

- pro sobeckou buňku: $1 + b \cdot N_A/5$,
- pro altruistickou buňku: $1 - c + b \cdot N_A/5$.

V každém kole simulace se vypočítá zdatnost všech buněk. Typ každé buňky na další kolo se rozhoduje na základě náhodností rulety mezi pěti buňkami z okolí (včetně sebe samé), přičemž šance na vítězství jsou úměrné zdatnosti.

Model obsahuje ještě dva parametry prostředí. Parametr nevlídnost udává, jak náročné je obsadit pole, které je prázdné. Parametr úmrtnost značí šanci, že buňka zemře (pole se stane prázdným).



Obr. 14.3: Buněčný automat modelující šíření altruismu. Význam barev: šedá = volné pole, černá = sobecká buňka, bílá = altruistická buňka. Horní řádek zachycuje vývoj za příznivých podmínek (nízká úmrtnost a nevlídnost), dolní řádek zachycuje vývoj za náročných podmínek (vysoká úmrtnost a nevlídnost).

Pokud jsou podmínky prostředí příznivé, tj. nevlídnost i úmrtnost jsou nízké, pak v simulaci dominují sobecké buňky, protože profitují na altruistech, nic je to nestojí, mají tedy větší zdatnost a postupně se rozšiřují populací. Pokud jsou však podmínky náročné, tj. je vysoká úmrtnost a je obtížné obsadit nová pole, pak začnou dominovat altruisté. Díky volným polím totiž mohou vzniknout oddělené skupinky altruistů, na kterých neprofitují žádní sobci. Skupinka altruistů se díky vzájemné podpoře dobře drží a rozrůstá, kdežto sobecké buňky v náročném prostředí stagnují.

Model s agenty

Podobný princip ilustrujeme ještě na modelu s agenty – krávy pasoucí se na louce (krávy jsou zde použity pouze pro názornost, model nemá přímou biologickou motivaci). Krávy se pohybují po louce (čtverečková síť), čímž spotřebovávají energii, a spásají trávu, čímž energii získávají. Pokud energie krávy překročí zadanou mez, kráva se rozmnoží, pokud energie klesne na nulu, kráva umře. Rychlost dorůstání trávy závisí na aktuálním množství trávy: pokud je trávy hodně, dorůstá rychle, pokud je však trávy málo, regenerace trvá dlouho. V modelu uvažujeme dva druhy

krav. Sobecké krávy spásají všechnu trávu, kdežto altruistické krávy vždy spásají jen trochu, aby mohla tráva rychle dorůstat.

Výsledky jsou podobné jako v předchozím případě. Klíčový parametr je tentokrát rychlost přesunu krav – pokud se krávy mohou přesouvat rychle (populační viskozita je vysoká), dominují sobecké krávy. Pokud se však krávy přesouvají jen pomalu (populační viskozita je nízká), dominují altruistické krávy.

Oba modely vykazují fenomén fázového přechodu popsany v kapitole 10, tj. přechod mezi dominancí sobeckého a altruistického chování je vzhledem k volbě parametrů velmi rychlý.

Souvislosti: Uvedené modely pocházejí z knihovny modelů nástroje NetLogo (Wilensky, 1998), podrobněji je popisují Mitteldorf a Wilson (2000) a Centola et al. (2000).

14.5 Shrnutí

- Dilema vězně je velmi jednoduchý model spolupráce a soutěžení, který však má mnoho praktických aplikací. Dilema vězně je hra s nenulovým součtem.
- Strategie TFT (tit-for-tat, oko za oko) se ukazuje jako velmi robustní – je úspěšná v mnoha různých prostředích. Úspěch této strategie ukazuje význam zpětné vazby (reciprocity) pro šíření spolupráce.
- Modely altruistického chování ukazují, jakou roli může hrát při šíření spolupráce příznivost (nepříznivost) prostředí a populační viskozita.
- Uvedené modelové situace ilustrují, jak může dojít k šíření spolupráce i v soutěživém prostředí.

15 Meze růstu

M: Našel jsem dobrý citát: „Chováme se jako Bůh, co se týče našeho plánovaného množení domácích rostlin a zvířat, ale současně se chováme jako králíci, co se týče našeho vlastního neplánovaného množení.“ To si taky myslím. Vlastně sám jsi to říkal – jsme jako králíci. Za chvíli se přemnožíme a přijde kolaps.

S: Já bych to neviděl zase tak černobíle. Přece jen jistý rozdíl mezi králíky a lidmi tady je. Lidé dokáží alespoň částečně dohlédnout důsledky svých činů a přizpůsobit svoje chování. Navíc nárůst velikosti populace se začíná zpomalovat.

M: Já myslím, že už je stejně pozdě a že se kolapsu nevyhneme. Dopadneme jako králíci, kteří si vyžrali všechnu trávu na palouku. Vždyť nám za chvíli dojdou zdroje.

S: Mám pocit, že vidíš svět trochu zjednodušeně. Každopádně myslím, že by tě mohla oslovit jedna známá studie s využitím modelů – jmenuje se Meze růstu a týká se témat, která jsi právě zmínil. Jde o klasiku v oblasti modelování, původní studie pochází ze 70. let a kniha napsaná na základě analýz modelu se stala velmi známou. Já osobně bych měl k vlastní studii pár výhrad, ale i tak ji mohu použít, abych ti ukázal, jak probíhá modelování ve velkém.

M: Tak povídej, jsem zvědav, k čemu ti modeláři dospěli. I když já v tom mám docela jasno – dopadneme jako ti králíci, jako ti králíci...

15.1 Úvodní poznámky

Když člověk připustí, že nic není jisté, tak musí, podle mého názoru, také připustit, že některé věci jsou daleko více jisté než jiné. (B. Russell)

V této kapitole popíšeme velký model komplexního systému, který využijeme pro shrnutí celého procesu modelování a ilustrujeme na něm souvislosti a možný dopad modelování. S využitím citátů autorů modelu znovu zdůrazníme nejdůležitější myšlenky o modelování komplexních systémů.

Volba modelu

Model, který rozebereme, pochází od výzkumníků z nevládní organizace Římský klub, což je organizace zabývající se mezinárodními politickými problémy. Model, který se jmenuje World3, i související série knih na téma „Meze růstu“ se zaměřují na problém růstu lidské ekonomiky a interakce rostoucí ekonomiky s limity planety.

Proč se zabýváme právě tímto modelem? Jde o jeden z nejznámějších modelů komplexních systémů. Model je dobře popsán a výklad autorů pěkně ilustruje základní fáze a principy modelování. Přístup autorů a jejich závěry jsou možná mírně kontroverzní, nicméně rozhodně jde o důležité téma.

Souvislosti: Předchůdcem modelu World3 byly modely, na kterých pracoval J. W. Forrester. Vlastní model World3 pochází od autorů Donelly Meadowsové, Denise Meadowse, Jorgena Randerse, kteří o něm napsali sérii knih: *Limits to Growth*, 1972 (původní studie), *Dynamics of Growth in a Finite World*, 1974 (technický detailní popis modelu), *Beyond the Limits*, 1993 (aktualizace původní studie po 20 letech), *Limits to Growth: 30-Year Update*, 2004 (aktualizace původní studie po 30 letech). Výklad v této kapitole vychází především z poslední z uvedených knih (Meadows et al., 2004).

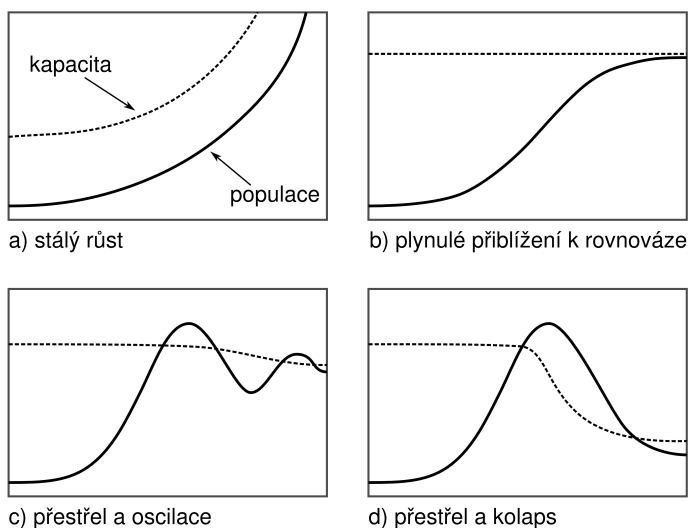
Původní verze modelu byla vytvořena v nástroji Dynamo, později byl model přepracován pro nástroj Stella – nástroj Stella je komerční, samotný model World3 je však dnes volně dostupný a zájemce si jej tak může důkladně prostudovat a vyzkoušet.

Účel studie

Prvním krokem modelování je ujasnění účelu modelu. V tomto případě musíme rozlišit účel samotného modelu a účel knih, které byly s využitím tohoto modelu napsány. Knihy totiž prezentovaly nejen model a výsledky simulací, ale také analýzy dat přímo nesouvisejících s modelem, názory a interpretace autorů. Hlavním účelem těchto knih je upozornit na zdánlivě zřejmý fakt, že v omezeném světě není možný neomezený růst.

Účelem vlastního modelu je zkoumání interakce lidské civilizace s nosnou kapacitou planety, konkrétněji hledání odpovědí na otázku: Jak může expandující globální populace a ekonomika interagovat a adaptovat se na nosnou kapacitu Země během následujících několika desetiletí? Formulace účelu modelu však nezůstává u této obecné otázky, ale je dále upřesněna. Autoři představují čtyři základní scénáře možného vývoje interakce ekonomiky a limitů planety (obr. 15.1). Primárním cílem modelování je určit, který z těchto scénářů je nejpravděpodobnější. V pozdějších edicích knih už autoři rozebírají dostupné statistiky o ekologické stopě a na jejich základě tvrdí, že již došlo k překročení mezí, a zabývají se otázkou: Jaké jednání zvýší šance k plynulému přechodu zpět pod tuto kapacitu? V řeči scénářů z obr. 15.1: Jaké jednání nám pomůže dostat se ke scénáři c) namísto scénáře d)?

Všimněme si, jak je účel modelu formulovaný:



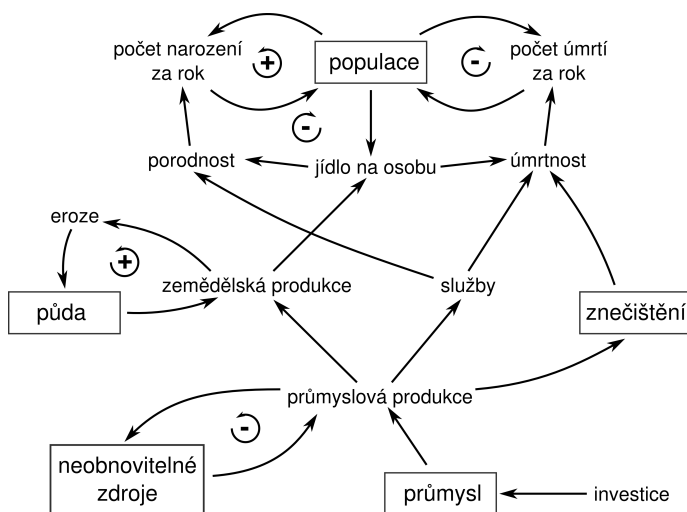
Obr. 15.1: Scénáře interakce ekonomiky a limitů planety (podle Meadows et al., 2004).

- modelujeme specifický problém (interakce ekonomiky a limitů planety), nikoliv celý systém (svět, planeta),
- je určen specifický časový rámec (řádově desetiletí dopředu) – model by určitě vypadal jinak, kdybychom si určili rámec v řádu let nebo století,
- jsou položeny konkrétní otázky (který ze scénářů pravděpodobně nastane, jak způsobit změnu), nicméně nejde o konkrétní číselné předpovědi, ale o obecné trendy.

Dále uvedme citaci autorů, ve které zdůvodňují svůj přístup k modelování. Toto zdůvodnění je použitelné pro mnoho modelů komplexních systémů: „Model, který jsme zkonstruovali, je, jako každý model, nedokonalý, velmi zjednodušený a nedokončený. (...) Základní módy chování, které v tomto modelu pozorujeme, se však ukazují být natolik fundamentální a obecné, že neočekáváme změnu našich široce pojatých závěrů při dalších revizích modelu.“

15.2 Model World3

Po stanovení účelu modelu můžeme přistoupit k vlastnímu sestavení modelu. Zde stručně nastíníme hlavní volby v průběhu konstrukce modelu, aniž bychom šli do detailů.



Obr. 15.2: Část zpětnovazebního diagramu zachycující hlavní prvky modelu. Obdélníkem jsou zvýrazněny klíčové zásobárny modelu.

Základní prvky modelu

Protože účelem modelu je zkoumání interakce růstu ekonomiky a limitů planety, model se musí soustředit na prvky, které s účelem bezprostředně souvisejí. Hlavními předměty zájmu jsou tedy: růstové procesy a zpoždění v systému, zdroje (obnovitelné, neobnovitelné), degradace zdrojů a znečištění.

Použitým modelovacím přístupem je systémová dynamika. Základem modelu jsou tedy zásobárny, tj. souhrnné proměnné určující stav systému. Podle výše uvedených hlavních předmětů zájmu můžeme klíčové zásobárny modelu rozdělit do pěti tříd:

- znečištění,
- neobnovitelné zdroje,
- populace,
- zemědělství (produkce jídla, úrodnost země, eroze),
- ekonomika (průmysl, služby, zaměstnanost).

Jakmile máme určeny základní zásobárny, musíme určit vztahy mezi nimi.

Obr. 15.2 ukazuje některé ze základních zpětnovazebních cyklů. Model obsahuje pouze pravidelné a průběžné události, tj. neobsahuje žádné války, nepokoje, epidemie, přírodní katastrofy. V tomto ohledu je tedy model značně optimistický.

Zásobárny a parametry

Jakmile jsou určeny základní vztahy, musí být zpřesněny. Je třeba konkretizovat přesně jednotlivé zásobárny, určit rovnice, které řídí jednotlivé vztahy, a pojmenovat parametry figurující v těchto rovnicích.

Většina informací je velice hrubě agregovaná. Například nejsou rozlišeny různé druhy neobnovitelných zdrojů či znečištění, místo konkrétních typů zdrojů či znečištění je použita jedna abstraktní položka. Autoři v popisu modelu zdůvodňují svoje volby zásobáren – argumentují, že pro jejich účel je vysoký stupeň agregace dostačující, a dokonce nutný, aby byl model pochopitelný.

Zohlednění účelu modelu při volbě dílčích zásobáren je dobře patrné na příkladech populace. Populace je v modelu rozdělena do čtyř základních věkových skupin, protože demografický vývoj přináší do systému zpoždění v řádu desítek let, které je velmi důležité pro celkovou dynamiku systému. Populace však již není rozlišena podle regionů či bohatství, protože takové rozlišení není pro studovanou otázku zásadní (kdybychom studovali migraci nebo konflikty, mohlo by tomu být naopak).

Parametry v případě modelu World3 představují především limity procesů, mezi ty nejdůležitější patří: množství kultivované země, úrodnost půdy, dosažitelná úroda, množství neobnovitelných zdrojů, schopnost absorbovat znečištění. Hodnoty parametrů autoři modelu odhadli, vesměs na základě dostupných historických statistik a odborných studií.

15.3 Analýza modelu

Jakmile je model hotový, můžeme přistoupit k analýzám: zkoumáme základní běh modelu, děláme analýzy citlivosti a provádíme experimenty s modelem.


Základní simulace

Připomeňme, že před samotnou analýzou je nutné provést validaci a verifikaci modelu. Tyto kroky zde nerozebíráme, jenom zmiňme, že všechny simulace prováděné s modelem začínají v roce 1900 a že model byl vyladěn tak, aby dosavadní průběh odpovídal realitě (retrodiķe). S takto vyladěným modelem autoři ukazují simulaci se základním nastavením parametrů modelu a bez přizpůsobování se (bez výrazných změn v jednání lidí). Tento scénář, který bývá nazýván „business as usual“, považují za standardní běh modelu, s nímž jsou ostatní porovnávány. Standardní běh (obr. 15.3) ukazuje vrchol většiny parametrů v první čtvrtině 21. století, po tomto vrcholu následuje prudký pokles.

Analýza citlivosti

Model samozřejmě obsahuje velké množství parametrů, které byly odhadnuty. Jak velký vliv mají tyto parametry na chování modelu? Může být chování modelu způsobeno jen konkrétní kombinací parametrů? Parametry byly podle názoru autorů optimisticky nadsazeny, nicméně i tak byly testovány různé změny parametrů směrem k většímu optimismu: zdvojnásobení zdrojů, lepší technologie pro kontrolu znečištění, zvýšení výnosů země, lepší ochrana proti erozi, efektivnější využívání zdrojů.

Autoři zkoušeli také různé kombinace těchto změn. Výsledky simulací jsou však stále podobné standardnímu běhu. Díky změnám dochází k oddálení vrcholu a ná-



Obr. 15.3: Výsledky simulace: základní scénář (podle Meadows et al., 2004).

sledného propadu (většinou zhruba do poloviny 21. století), případně propad není tak výrazný jako u standardního běhu. Nicméně základní trend „přestřel a kolaps“ stále zůstává.

Později provedli další výzkumníci podrobnější analýzy citlivosti, které tyto výsledky mírně zpochybnily (Miller, 1998). Pomocí automatizovaných metod prohledávání, které zkoušely různé variace hodnot proměnných v rozmezí desetiprocentní odchylky od původních hodnot, byly nalezeny kombinace hodnot proměnných, které se trendu „přestřel a kolaps“ vyhýbají. Nicméně „přestřel a kolaps“ je nejdominantnějším typem chování modelu.

Zásahy do systému

Další typ analýzy spočívá v experimentech s modelem. Autoři konkrétně studovali následující změny chování lidské civilizace:

- kontrola porodnosti,
- stabilizovaná průmyslová produkce, snížení emisí,
- rychlý vývoj technologií pro snížení eroze a lepší využití zdrojů.

Kromě efektů změn zkoumali autoři také efekt jejich načasování. Do modelu umožnili zapojení změn v různých časových okamžicích: konkrétně v letech 1975, 1995 a 2015. Z těchto analýz vyplynulo, že uvedené zásahy mohou mít výrazný vliv na chování modelu a také že rozdíl 20 let může hrát díky nelinearitám velkou roli. V případě včasného „zapnutí“ všech změn směřuje vývoj k relativně stabilnímu stavu a vyhne se kolapsu.

15.4 Závěry a souvislosti

Velice důležitou součástí modelování je také interpretace výsledků simulací a formulace závěrů. Studie Meze růstu měla svoje závěry formulovány natolik jasně, že vzbudily i rozsáhlou reakci.

Závěry studie

Autoři shrnují výsledky svých analýz následovně: „Pokud současné trendy růstu světové populace, průmyslu, znečištění, produkce jídla a čerpání zdrojů budou pokračovat, limity růstu na této planetě budou dosaženy někdy během následujících sta let. Nejpravděpodobnějším důsledkem dosažení těchto limitů bude náhlý a nekontrolovatelný pokles velikosti populace a životní úrovně.

Je však možné změnit současné trendy růstu a ustavit podmínky ekonomické a ekologické stability, které jsou udržitelné dlouho do budoucna. Takový stav celosvětové rovnováhy může být navržen tak, aby základní životní potřeby všech lidí byly uspokojeny a každý člověk na Zemi měl stejnou šanci realizovat svůj lidský potenciál.

Pokud se lidé rozhodnou směřovat radši k druhému než k prvnímu výsledku, pak čím dříve začnou pracovat na jeho naplnění, tím větší budou jejich šance na úspěch.“

Všimněme si, jak jsou tyto závěry formulovány:

- Závěry se vztahují k původní otázce, k účelu modelu.
- V závěrech jsou nastíněny trendy ohledně základních módů budoucího chování, nikoliv konkrétní předpovědi.
- Závěry rámcově odpovídají provedeným simulacím, jsou však zobecněny a interpretovány.

Nutno však podotknout, že uvedené závěry jsou závěry celé knihy, a nikoliv jen práce s modelem. V knize autoři rozebírají i některé další zdroje informací (statistiky, příklady) a promítají do ní i svoje názory. Kdybychom brali tyto závěry čistě jako závěry analýz modelu, šlo by o příliš velké a neopodstatněné zobecnění.

Reakce

Když v roce 1972 vyšla první kniha popisující model World3, vzbudila velký ohlas. Stala se světovým bestsellerem, výrazně ovlivnila environmentální hnutí, které se na počátku 70. let pomalu rodilo, a přispěla k obecnému uvědomění si konečných limitů naší planety. Toto uvědomění bylo během následujících let výrazně posíleno ropnou krizí. I následující revize knihy z let 1993 a 2004 vyvolaly velký zájem. K přímému ovlivnění politiky a rozhodování na vrcholné úrovni, což byl zřejmě jeden z cílů autorů, však nedošlo.

Knihou ovšem vyvolala také velkou kritiku, například časopis *Newsweek* ji označil za „nezodpovědný nesmysl“. Část kritiky byla povrchní a týkala se spíše nepochopení obecných principů modelování a účelu modelu (model je příliš abstraktní, parametry jsou pouze odhadnuté, předpovědi se nenaplní) nebo byla způsobena hlavně jiným postojem ke světu (je to jen další předpověď zkázy, jakých už byla spousta).

Objevila se však také kritika hlubší a často oprávněná: v modelu je nedostatečný (podceněný) prostor pro inovace, rozvoj technologie a lidskou fantazii, model má tvrdé limity, neumožňuje příliš přechod k náhradám, v modelu je vestavěná zaujatost (např. ekonomický růst nemusí způsobovat nárůst znečištění, často je tomu naopak).

Autoři studie zmiňují při analýzách mimo jiné variantu modelu, kterou nazývají „nesmysly dovnitř, nesmysly ven“. Jde o variantu modelu, ve které odstraní většinu

klíčových limitů a tím pádem dostanou na výstup neomezený růst. Kritika autorů bývá občas shrnována parodií na tento slogan: „pesimismus dovnitř, pesimismus ven“. Výstupy modelů jsou vždy jen mechanicky dotažené důsledky vložených předpokladů (vstupů). Pokud vložíme do modelu pesimistické předpoklady, dá se očekávat, že dostaneme pesimistické výstupy.

Autoři modelu se domnívají, že jejich předpoklady jsou optimistické, kritici je považují za pesimistické. Jak to tedy je? Světová ekonomika a limity planety jsou natolik složité, že nelze očekávat jednoduchou odpověď, na které by se všichni shodli. Nicméně i pokud se s předpoklady autorů neztotožníme a nepřijmeme závěry jejich analýz, model nás nutí přemýšlet o našich vlastních předpokladech a jejich pravděpodobných důsledcích. Toto je jeden z klíčových přínosů modelování – zviditelňuje naše myšlenky a umožňuje nám o nich konstruktivně diskutovat (nebo se také nekonstruktivně pohádat, jak je komu libo).

Klíčovým tématem této studie je téma růstu. Neustálý ekonomický růst je klíčovým principem současné civilizace. Autoři se pomocí modelu snaží zviditelnit tento princip a ukázat, že nekontrolovaný růst může vést k problémům. Kritici často obviňovali autory ze zastávání se nulového růstu, který by vedl ke kolapsu ekonomiky. Autoři v odezvách shrnují svůj postoj sloganem: „Nikoliv slepá opozice k růstu, ale opozice k slepému růstu.“ Princip, který autoři obhajovali již ve své první knize z počátku 70. let, byl v podstatě trvale udržitelný růst – autoři však mírně předběhli dobu, protože pojem „trvale udržitelný růst“ se objevil až během 80. let.

Poučení pro modelování

Ať už s přístupem autorů studie a jejich závěry souhlasíme nebo ne, můžeme si z této studie odnést cenná poučení ohledně modelování. Postup autorů dobře ilustruje jednotlivé fáze modelování: jasně formulují svůj cíl, navrhují základní strukturu modelu vzhledem k tomuto cíli, budují spustitelný model s využitím relevantních dat, provádějí analýzy citlivosti a experimenty s modelem a formulují jasné závěry.

Model je sice rozsáhlý, ale principiálně komplikovaný není. Nepoužívá nic složitějšího než techniky popsané v kapitole 6.1. Model byl vypracován v 70. letech, kdy byly možnosti počítačů výrazně nižší než dnes. I přesto se mu podařilo vyvolat velkou odezvu. Znalost složitých technik a výkonné počítače nám mohou při modelování komplexních systémů rozhodně pomoci, ale tím hlavním je dobrý nápad. Jak již bylo řečeno v kapitole 5: modelování není jenom věda, ale také umění.

15.5 Shrnutí

- World3 je systémový model, jehož účelem je zkoumání možných scénářů interakce rostoucí ekonomiky a limitů planety.
- Jde o rozsáhlý model, na kterém lze ilustrovat typické prvky modelování komplexních systémů.

-
- Autoři modelu World3 napsali sérii knih, která vychází z analýz modelu. Tyto knihy se především snaží upozornit na zdánlivě samozřejmý fakt, že v omezeném světě není možný neomezený růst.
 - Model a především související knihy vyvolaly širokou odezvu (pozitivní i negativní).

16 Příklady aplikací modelování

M: Seminárku už mám skoro hotovou. Uznávám, že ukázky modelů práci zpestřily a já jsem si při modelování dobře ujasnil mnoho souvislostí. Ale byly to samé malé modely, jednoduché ukázky. Zajímalo by mě, jestli se používá modelování i ve velkém. Prostě jinak než na ukázky ze života králíků.

S: Když zůstaneme u modelování živých tvorů a života obecně, tak příkladem modelování ve velkém je systémová biologie. Jde o oblast výzkumu zabývající se biologickými mechanismy na úrovni buněk. Modely se zde využívají pro testování hypotéz a jako součást výzkumného cyklu – je daleko snadnější a levnější experimenty nejdříve odsimulovat na počítači a teprve pak dělat vybrané experimenty naživo.

M: To je ale pořád spíš výzkum, bádání, porozumění světu. Nic proti tomu, ale zajímala by mě pořádná aplikace s konkrétním dopadem na můj život.

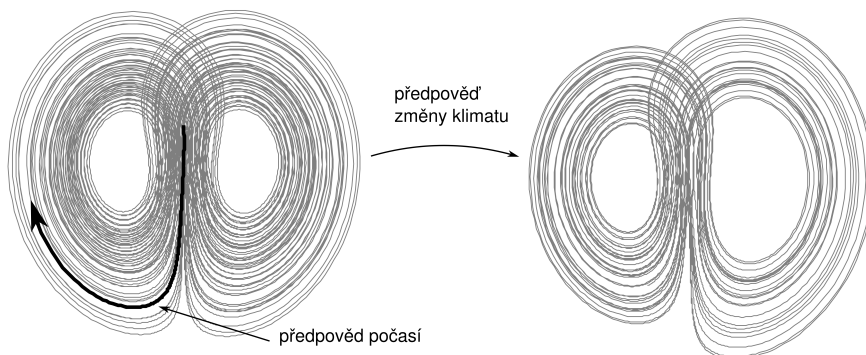
S: Dobrá, tak jinak. Bereš si na zítřejší výlet pláštěnku?

M: Neberu, má být jasno. Ale počkej, výlet probereme za chvíli, teď neodváděj pozornost a odpověz mi na moji otázku. Existují aplikace modelování s přímým dopadem na můj život?

S: Vždyť už sis sám odpověděl. Bereš si zítra pláštěnku? Nebereš, protože má být jasno. Jak víš, že má být jasno? Protože to pán v televizi vyvěstil z čajových lístků?

M: No dobře, nemusíš ze mě dělat hlupáka, už je mi to jasné. Předpověď počasí je nejspíš shrnutí výsledků modelů. Hádám, že tyhle modely mají trochu víc proměnných, parametrů a vztahů než moje modely s králíky.

S: To si piš, předpovídání počasí je jedna z oblastí, která už od 50. let žene kupředu vývoj počítačů, protože tyhle modely jsou velmi výpočetně náročné. Anebo příklad z jiné oblasti – zachytil jsi diskuze o stavbě dálnice R43 u Brna? Viděl jsem mapky, které ukazovaly předpověď intenzity dopravy v budoucnosti při různých variantách této dálnice. Tyto mapky byly samozřejmě výstupem modelů. To máš příklad modelování v dopravě, což je další rozšířená oblast.



Obr. 16.1: Lorenzův model: průmět stavového prostoru pro dvě různé hodnoty parametrů, na levém obrázku je vyznačen začátek trajektorie.

16.1 Modelování počasí a klimatu

V této kapitole se podíváme na několik oblastí, ve kterých se intenzivně využívají modely, a to modely velmi rozsáhlé. V tomto případě se nebudeme pouštět do detailů, ale zmíníme pouze hlavní principy modelů, způsoby jejich použití a historické souvislosti.

První oblast, kterou rozebereme, je modelování počasí a klimatu. Začneme ujasněním rozdílu mezi počasím a klimatem. Pojem „počasí“ označuje aktuální stav atmosféry (např. teplota, srážky, vítr), kdežto pojem „klima“ označuje dlouhodobé vzorce počasí v určité části světa. Modelování počasí je zaměřeno lokálně, na krátkodobou předpověď v řádu dnů a cílem je co největší přesnost předpovědi. Modelování klimatu je zaměřeno globálně, dlouhodobě a cílem je určit obecné trendy. Předpovídání počasí je významné komerčně (např. zemědělství, letecká doprava, turistika), modelování klimatu je významné vědecky a politicky (jednání o změnách klimatu).

Rozdíly mezi modelováním počasí a klimatu můžeme ilustrovat pomocí Lorenzova modelu (obr. 16.1). Jde o velmi abstraktní model klimatického systému sestávající z pouhých tří diferenciálních rovnic – na tomto modelu objevil Lorenz v 60. letech principy chaotického chování. Při modelování počasí jde o co nejpřesnější určení krátkodobého chování, tj. určení začátku trajektorie pro dané počáteční podmínky. Při modelování klimatu jde o tvar celého „atraktoru“ (obrázku jako celku) a o změny atraktoru při změnách parametrů systému (např. množství CO_2 v atmosféře).

Počasí

O předpovídání počasí se pokoušejí lidé od pradávna a výrazný vliv na život má předpovídání počasí minimálně od počátků zemědělství. Až do 19. století bylo předpovídání počasí založeno pouze na pozorování lokálních znaků a na znalosti pravidelných

vzorů počasí. I zde už můžeme mluvit o modelech, například lidové pranostiky vlastně nejsou nic jiného než hrubé modely pro předpovídání počasí.

V 19. století byl objeven telegraf a bylo tak možno dělat předpovědi na základě větších oblastí. Formulace předpovědi počasí jakožto matematicko-fyzikálního problému se objevila poprvé roku 1904 a roku 1922 byl navržen princip předpovědi počasí pomocí matematických výpočtů – počítače v té době ještě neexistovaly, takže návrh počítal s manuálními výpočty, což bylo prakticky nerealizovatelné. Jakmile se však objevily počítače, stalo se předpovídání počasí okamžitě jednou z důležitých aplikací – první jednoduché výpočty proběhly již v roce 1950 na prvním počítači ENIAC a již od roku 1955 probíhají rutinní numerické předpovědi.

Proces předpovídání počasí má několik fází:

1. Získání a zpracování dat o aktuálním stavu atmosféry.
2. Simulace pomocí modelů.
3. Statistické zpracování výsledků simulací.
4. Prezentace výsledků.

Data o aktuálním stavu atmosféry se získávají z mnoha zdrojů, které pokrývají Zemi velmi nepravidelně (např. pozemní stanice, letadla, satelity). Modely počasí pracují s pravidelnými mřížkami, a je tedy potřeba naměřená data předzpracovat, což má na starosti proces zvaný „asimilace dat“. Vstupem tohoto procesu jsou naměřená reálná data a výstupem je pravidelná mřížka s aproximovanými daty.

Vlastní model představují rovnice zachycující vývoj počasí. Základ modelu tvoří „dynamika“, což jsou obecné vztahy, jako například přesuny vzduchu vlivem rozdílů tlaku nebo ochlazování (ohřívání) vlivem rozpínání (stlačování) vzduchu. Krom těchto základních rovnic je pro věrohodnou předpověď potřeba doplnit detaily, například výměnu energie mezi atmosférou a okolím (země, moře), mikrofyziku mraků a srážek nebo procesy s menším rozlišením, než je rozlišení modelu. Těmto doplněním se říká „parametrizace“ modelu.

Základním typem modelů jsou mřížkové modely, což jsou v podstatě buněčné automaty. Trojrozměrný prostor je rozdělen do diskrétní pravidelné mřížky. Pro každé pole mřížky udržujeme aktuální stavové informace (např. teplota, vlhkost, tlak) a v diskrétních časových krocích tyto stavové informace aktualizujeme na základě zmíněných rovnic. Alternativně lze použít spektrální modely, ve kterých jsou některá data (např. tlak) uložena ve formě prostorové vlny.

Pro představu o tom, jak vypadá reálný model počasí, zmiňme model GFS (Global Forecast System). Tento model provozuje americká organizace NOAA (National Oceanic and Atmospheric Administration) a jde o jeden z mála modelů, jehož výstupy jsou volně dostupné přes internet. Velká část předpovědi počasí dostupných na internetu tudíž čerpá podklady právě z modelu GFS. Horizontální rozlišení modelu (jedno pole mřížky) je 35 kilometrů, vertikálně model rozlišuje 64 úrovní. Na rozdíl od horizontální mřížky jsou vertikální úrovně nepravidelné – u povrchu jsou úrovně hustší než ve velkých výškách. Časové rozlišení (jeden krok simulace) je v řádu minut až hodin. Výstupem modelu je detailní předpověď na 7 dní a hrubá předpověď na 16 dní. Jak vypadá graficky zpracovaný výstup modelu, jistě není třeba osvětlovat.

Souvislosti: Základní přehled o modelování počasí lze získat například z internetového kurzu COMET (2006). V České republice se výpočetním modelováním počasí zabývají dvě organizace. Český hydrometeorologický ústav provozuje model Aladin, což je rozsáhlý mezinárodní projekt vycházející ze spolupráce více než deseti převážně evropských států. Ústav informatiky Akademie věd provozuje v rámci projektu Medard model MM5 vyvíjený na americké Pennsylvania State University.

Klima

Na rozdíl od předpovídání počasí, kterým se lidé zabývají již dlouho, modelování klimatu se řeší teprve posledních pár desítek let. Kvůli změnám klimatu způsobeným lidskou aktivitou je však v současnosti modelování klimatu klíčovým tématem s dopadem na mezinárodní politiku.


Ve zkoumání změn klimatu hraje důležitou roli mezinárodní organizace IPCC (Intergovernmental Panel on Climate Change). IPCC neprovádí přímo výzkum, ale sdružuje velké množství vědců, kteří společně jednou za pět let sepiší rozsáhlou zprávu o současném stavu vědomostí z oblasti změn klimatu (první zpráva vyšla v roce 1990, čtvrtá zpráva, zatím poslední, vyšla v roce 2007). Zprávy IPCC, které již mají i výrazný mediální a politický dopad, jsou do velké míry založeny na výsledcích modelů.

Abychom dali použití modelů do souvislostí, zmiňme hlavní kroky při zkoumání změn klimatu:

1. Zjištění dat o vývoji klimatu, tj. měření relevantních dat a rekonstrukce údajů z minulosti pomocí využití proxy dat (např. bubliny zachycené v ledu, letokruhy stromů).
2. Analýza dat z minulosti a návrh vysvětlení, tj. zkoumání fyzikálních jevů ovlivňujících klima a návrh hypotéz vysvětlujících fungování klimatu.
3. Předpovědi vývoje klimatu. Předpovědi se tvoří pomocí modelů, které jsou založeny na datech a rovnicích podle prvních dvou bodů. Modely, jež započítávají i vliv lidské aktivity, používají jako vstup také předpovědi vývoje civilizace (zejména emise skleníkových plynů), na tyto předpovědi se používají samostatné modely.
4. Formulace závěrů výzkumu a v optimálním případě také adekvátní akce.

Podívejme se nyní blíže na použití modelů. Neexistuje jeden univerzální typ modelu, který by se používal pro zkoumání změn klimatu. Místo toho se používá celá hierarchie modelů od detailních trojrozměrných až po jednoduché abstraktní.

Detailní trojrozměrné modely se označují termínem „Coupled Atmosphere-Ocean General Circulation Models“. Jsou svým principem podobné modelům pro předpovídání počasí, oproti nim jsou však mírně hrubší. Modely pracují s trojrozměrnou mřížkou pokrývající celou Zemi, rozlišení je zhruba 1 bod na 3 stupně zeměpisné šířky



Obr. 16.2: Rekonstrukce klimatu 20. století. Plná čára ukazuje reálnou průměrnou teplotu, šedé bloky ukazují kombinované výsledky simulací modelů, přičemž tmavší blok odpovídá simulacím bez zahrnutí lidských aktivit, světlejší blok odpovídá simulacím zahrnujícím lidské aktivity (podle IPCC, 2007).

(výšky), 30 výškových (hloubkových) úrovní, časový krok v řádu hodin. Tyto modely jsou výpočetně náročné, a tedy nepříliš vhodné pro vyložení dlouhodobé simulace.

V případě jednoduchých abstraktních modelů je složitost výrazně redukována – používají se dvojrozměrné i jednodušší modely. Tyto modely jsou výpočetně nenáročné, a mohou tak být spouštěny pro velkou škálu parametrů. Díky tomu umožňují zkoumání role zpětných vazeb v klimatu, citlivosti klimatu a principiálních možností vývoje (např. vliv zpětné vazby mezi rozlohou ledovců, albedem a teplotou planety).


Mezi detailními a abstraktními modely jsou svojí složitostí středně složitě modely označovány termínem „Earth System Models of Intermediate Complexity“. Tyto modely se zaměřují vždy na určitý aspekt klimatu, jsou relativně detailní, ale umožňují simulace s dlouhodobým výhledem a analýzy citlivosti. Příklady těchto modelů jsou dvojrozměrné svázané modely atmosféra-oceán, statistické atmosférické modely a modely oceánu a srážek.

Výsledky simulací z různých typů modelů se kombinují a statisticky zpracovávají. Pro ilustraci uvádíme dva takové zpracované sumární výstupy, viz obr. 16.2 a 16.3.

Souvislosti: Dobrým startovním bodem k informacím o modelování klimatu je zpráva IPCC (2007). Příklad konkrétního modelu klimatu je CM2.X (<http://nomads.gfdl.noaa.gov/CM2.X/>).

16.2 Modelování dopravy

Doprava je velmi zajímavý komplexní systém. Jde o systém tvořený výlučně lidskou aktivitou, lidé ho navrhují a snaží se jej řídit, ale přitom mu příliš nerozumí. Modelování je proto důležitým pomocníkem při snaze pochopit a řídit dopravu a také se v této oblasti intenzivně a ve velkém používá.



Obr. 16.3: Výsledky simulací – změna průměrné teploty při různých scénářích vývoje lidské aktivity, nulový scénář odpovídá zachování koncentrací skleníkových plynů na úrovni roku 2000. Tmavé čáry zobrazují průměr z mnoha modelů, šedé bloky zobrazují rozptyl odpovídající standardní odchylce z výsledků (podle IPCC, 2007).

Účel modelů

Podobně jako u mnoha jiných modelů komplexních systémů i u modelů dopravy může být účelem modelování porozumění systému nebo předvídání budoucího chování. V oblastech světa, kde je obzvláště hustá doprava, například televizní stanice přinášejí kromě předpovědi počasí také předpověď dopravy. Na rozdíl třeba od počasí však jde o systém, který nejenom výrazně ovlivňuje naše životy, ale který můžeme také do velké míry ovlivňovat my. Účelem modelů je proto často plánování a vyhodnocování možných zásahů do dopravy. Příklady konkrétních otázek, které se s pomocí modelování řeší:

- Porozumění fungování dopravy: Jak vznikají zácpy a jak jim zabránit?
- Plánování nových silnic: Jak ovlivní nová silnice dopravu? Kudy ji postavit? Má to vůbec smysl?
- Řízení dopravy: Jak ovlivní uzavírka dopravu? Jak postavit křižovatku, aby byl provoz co nejplynulejší a nejbezpečnější? Jak řídit světelnou signalizaci?
- Parkování: Kam umístit parkovací místa?
- Poplatky: Jak ovlivní výběr mýtného dopravu? Jaký zvolit systém parkovného? Jaké budou výnosy?
- Hromadná doprava: Kudy vést trasy hromadné dopravy? Jak často by měly spoje jezdit? Jak přizpůsobit dopravu mimořádné události (sportovní zápas, ohňostroje)?
- Dopad na okolí: Jak velké znečištění (hluk) doprava vytváří? Která místa jsou nejhůře postižena? Jak efektivně zabránit vzniku a šíření znečištění (hluku)?

Za speciální případ dopravy můžeme považovat přesun lidí pěšky. Modelovat přímo přesun lidí má smysl především v případě velkých davů, které se vytvářejí například v přestupních uzlech, při požárech ve velkokapacitních prostorech (koncerty, sportovní zápasy) nebo při pouti Hadž. Cílem modelování je navrhnout uspořádání prostoru tak, aby dav lidí mohl plynule proudit a aby nedocházelo k tlačenicím a předešlo se katastrofám (ušlapání lidí).

Modely, které používáme k výše zmíněným účelům, lze rozdělit na dva základní typy: mikrosimulace a makrosimulace.

Mikrosimulace

Mikrosimulační modely jsou vhodné pro zachycení problémů na lokální úrovni, např. jedna křižovatka. V mikrosimulaci reprezentujeme přímo konkrétní tvary prostoru a jednotlivá auta (případně jiné dopravní prostředky), jde tedy v principu o modely s agenty. Pohyb agentů-aut je odvozen z: fyzických vlastností (např. délka, maximální zrychlení), fyzikálních zákonů (např. vztahy mezi ujetou vzdáleností, rychlostí, zrychlením) a pravidel pro chování řidiče (např. změna jízdního pruhu, odstup od nejbližšího auta).

Mikrosimulační modely můžeme použít na úrovni jednoduchých abstraktních modelů pro demonstraci některých neintuitivních jevů, které se v dopravě objevují. Příklady tohoto typu jsou model „decentralizovaného“ vzniku zácpy bez vnější příčiny nebo model situace, ve které může omezení maximální rychlosti zlepšit dopravní propustnost. Mikrosimulační modely se však používají také pro řešení konkrétních reálných situací, typicky například návrh křižovatky či řízení světelné signalizace v systému navazujících křižovatek.

Makrosimulace

Makrosimulační modely pracují na vyšší úrovni (celé město, stát) a neoperují s jednotlivými objekty, ale se sumárními statistickými informacemi. Dopravní síť v tomto případě zaznamenáváme pomocí abstraktního grafu, ve kterém jsou zachyceny vztahy mezi dopravními uzly (křižovatky) a hrany nesou informace o propustnosti. Pohyb objektů je popsán pomocí rovnic, které udávají proudění dopravy pomocí sumárních informací (např. hustota dopravy, průměrná rychlost).

Důležitou součástí modelů je také modelování „vzniku“ dopravy – odkud, kam a kudy lidé jedou. Vznik dopravy modelujeme na základě demografických dat (kde lidé bydlí, kde pracují) a pomocí jednoduchých modelů lidského rozhodování (např. „snažím se jet nejkratší cestou, ale pokud je tam už třetí den zácpa, zkusím jet jinudy“).

Pro modelování dopravy existují rozsáhlé komerční programy, které umožňují modelování na několika úrovních, propojení s demografickými a geografickými daty a automatické zpracování výstupů modelů, včetně například vizualizací provozu a trojrozměrných animací (náhled z ptáčích perspektivy i z perspektivy řidiče).

Souvislosti: Příklady jednoduchých a přitom názorných mikrosimulací lze nalézt na webu <http://traffic-simulation.de>. Příkladem rozsáhlého nástroje pro modelování dopravy je systém EMME. Simulováním davu lidí se zabývá například Still (2000).

16.3 Systémová biologie

Někteří lidé předpovídají éru systémové biologie, ve které je schopnost vytvářet matematické modely popisující funkci sítě genů a proteinů stejně důležitá jako tradiční laboratorní dovednosti. (D. Butler)

Systémová biologie je velmi mladá oblast výzkumu – tento pojem se ve větší míře používá zhruba od roku 2000, v současnosti jde stále spíše o populární termín, který nemá jednoznačný význam a jež každý používá, jak se mu hodí. Většinou se systémová biologie charakterizuje jako úsilí porozumět chování biologických systémů jako celku, čehož se snaží dosáhnout zaměřením se i na komplexní interakce mezi částmi a na celkové chování, nejen na redukcionistický rozbor jednotlivých částí.

Systémová biologie těsně souvisí s bioinformatikou – další populární pojem bez přesného významu, který zjednodušeně řečeno označuje intenzivní využití počítačů v molekulárně biologickém výzkumu. Nebudeme rozebírat pojmy, podíváme se raději na hlavní principy. Existují dva základní způsoby využití počítačů v biologickém výzkumu:

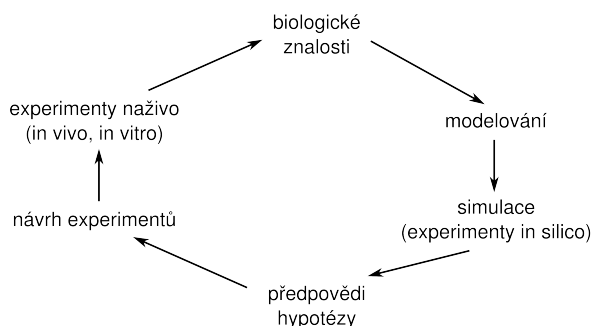
1. Objevování znalostí: použití počítačů pro získávání rozsáhlého množství dat, jejich ukládání, zpracování a analýzu (např. sekvenování genomu).
2. Modelování a simulace: použití počítačů pro vytváření a analýzu modelů biologických systémů a pro porovnávání výstupů simulací s reálnými daty.

Zde stručně nastíníme pouze použití počítačů pro modelování.

Role modelování

Biologie, jako každá jiná věda, samozřejmě používá modely již velmi dlouho. Tradiční modely v biologii mají formu slovních popisů a neformálních diagramů, které zachycují pouze kvalitativní vztahy. Takovéto modely ovšem není možno simulovat a často není ani možné přímo falzifikovat hypotézu zachycenou modelem. Systémová biologie klade důraz na simulovatelné kvantitativní modely, jejichž výstup je možné porovnat s výsledky experimentů, a z toho plynoucí možnost ověření platnosti modelů. Případně můžeme pomocí těchto modelů stanovovat konkrétní hypotézy, které se posléze pomocí experimentů ověřují.

Experimenty v biologii v minulosti probíhaly buď *in vivo* (s živými organismy přímo v původním prostředí), nebo *in vitro* (s živými organismy v laboratorních podmínkách). Simulovatelné modely nyní dávají třetí způsob provádění experimentů – ten bývá označován jako *in silico*.



Obr. 16.4: Idealizovaný cyklus výzkumu v systémové biologii (podle Kitano, 2002a).

Obr. 16.4 zachycuje idealizovaný průběh výzkumu v systémové biologii. Tento postup kombinuje modelování a experimenty *in silico* s tradičními postupy. Průběh výzkumu tvoří cyklus, ve kterém vyrábíme modely na základě našich aktuálních biologických znalostí, na základě výsledků simulací vytváříme nové hypotézy o chování reálných systémů, tyto hypotézy následně ověřujeme pomocí experimentů na živo, čímž si ujasňujeme platnost navržených hypotéz a rozšiřujeme biologické vědomosti.

Podobný cyklus lze aplikovat i na vývoj léků. Hiroaki Kitano, jeden z protagonistů systémové biologie, dokonce považuje za představitelné, že v budoucnosti se budou vyžadovat při schvalování nových léků formální modely účinku léku a výsledky simulací interakcí s jinými léky, podobně jako jsou při schvalování výškových budov požadovány plány a analýzy odolnosti při zemětřesení.

Souvislosti: Detailnější rozbor uvedených principů lze najít v pracích Hiroakiho Kitana, viz např. Kitano (2001), Kitano (2002a), Kitano (2002b) a dále například ve sborníku od editorů Szallasi et al. (2006).

Příklady použití modelů

Pro ilustraci výzkumu v oblasti systémové biologie zmiňme několik příkladů. V biologickém výzkumu hrají důležitou roli takzvané modelové organismy, které mají biologové důkladně prostudovány, a o nichž jsou tedy k dispozici velmi detailní informace. Právě tyto organismy, mezi které patří například bakterie *Escherichia coli* nebo červ *Caenorhabditis elegans*, jsou typicky předmětem modelování v systémové biologii.

Příkladem obecného problému, který nás v systémové biologii může zajímat, je diferenciací buněk. Všechny buňky jednoho organismu nesou stejnou genetickou informaci. Jak tedy dochází k tomu, že se organismy skládají z různých buněk? Jak to, že ze stejného základu vznikne jednou svalová a jindy srdeční anebo nervová buňka? A jak to, že srdeční buňky vznikají tam, kde mají, a ne třeba na palci u nohy? Základem těchto mechanismů jsou složité vztahy mezi geny a bílkovinami. Geny kódují, které bílkoviny se mají vytvářet, přítomnost bílkovin však zpětně ovlivňuje expresi

genů – bílkovina může projevy genu umocňovat nebo tlumit. Vývoj buňky tak závisí nejen na genetické informaci, ale i na prostředí, v jakém se nachází, a na „signálech“, které dostává od okolních buněk. Laicky řečeno, v palci u nohy není to správné prostředí pro expresi genů potřebných pro vznik srdeční buňky.

V předchozím odstavci jsme stručně nastínili, jak funguje určitý biologický mechanismus (diferenciace buněk). Ovšem ukázat, jak funguje tento mechanismus přesně, je pěkně složité. Zde přicházejí na řadu modelové organismy. Místo toho, aby vědci studovali vývoj buněk na palci u lidské nohy, studují například vývoj vulvy u červa *C. elegans*. U něj má vulva právě šest buněk, a tak je reálné zhotovit relativně přesný model popsaného mechanismu včetně konkrétních numerických hodnot (Fischer, 2005).

Uveďme namátkou několik dalších problémů, které se studují v systémové biologii (Szallasi, 2006):

- Biologické hodiny. Většina organismů si udržuje relativně pravidelný životní rytmus. Jak fungují tyto „biologické hodiny“? Může jít například o pravidelně oscilující reakce chemických látek.
- Robustnost buněk. Buňky často vykazují vysokou robustnost – dokáží fungovat za mnoha různých podmínek. Čím je tato robustnost způsobena – spíš duplicitou (klíčové informace kódovány vícekrát), nebo zastupitelností (pokud vypadne jedna bílkovina, nahradí ji jiná)?
- Chomataxe bakterií. I velmi jednoduchá bakterie, která se pohybuje pouze pomocí nepříliš sofistikovaného bičíku, se dokáže pohybovat směrem k „jídlu“ (směrem zvýšené koncentrace pro ni příznivých látek). Jak toho dosahuje?

16.4 Shrnutí

- Modelování se používá nejen pro malé abstraktní modely, které demonstrují základní principy, ale také pro detailní modely, pomocí nichž můžeme tvořit konkrétní předpovědi.
- Modelování počasí je typickou aplikací modelování, jež ovlivňuje náš každodenní život. Základní princip modelů počasí není složitý, ale pro získání věrohodných předpovědí je potřeba naplnit modely rozsáhlými daty a provádět výpočetně náročné simulace.
- Modelování klimatu probíhá principiálně podobně jako modelování počasí, dopad modelování klimatu je však spíše vědecký a politický.
- Modelování dopravy je typický příklad modelování lidmi vytvářeného komplexního systému, kde se snažíme systém nejen pochopit, ale také ovlivňovat jeho budoucí chování.
- Systémová biologie je mladá oblast biologického výzkumu, ve které se za pomoci počítačových modelů snažíme pochopit chování biologických systémů jako celků.

17 Pákové body

M: Tak seminárka už je odevzdaná i se všemi modely. Musím uznat, že jsi mi ukázal docela zajímavé věci. Ale taky jsem zjistil, že modelování je náročné a zabere hodně času. Zajímalo by mě, jestli to, co jsem se naučil, mohu použít v běžném životě. Tak nějak za běhu, bez toho, abych dělal přesné modely.

S: Myslím, že se ti to bude určitě hodit. Modelování tě učí určitým způsobem myslet a dívat se na svět a tento pohled můžeš uplatnit i bez přímého využití modelů. Například při hledání pákových bodů.

M: Co je to?


S: Pákové body jsou místa v komplexním systému, u kterých malá změna může způsobit velké následky. Většina lidí tento pojem asi nikdy neslyšela, nicméně víra v existenci pákových bodů je v nás zakořeněna v mnoha příbězích a legendách – stříbrná kulka, Achillova pata, kouzelné heslo, hrdina, který se objeví a zvrátí celou historii, kritické místo vesmírné lodi, kam se stačí trefit a bitva je vyhrána.

M: Počkat, to už ses od toho formálního modelování vzdálil trochu moc. Skutečný život je složitější než legendy.

S: To samozřejmě je, nicméně i tak je velký rozdíl mezi různými způsoby, jak ovlivňovat chování systému. Představ si jednoduchý příklad – chceš se dostat na druhý břeh divoké řeky. Můžeš nasednout do loďky a začít zběsile pádlovat přímo směrem k druhému břehu. Časem se tam sice dostaneš, ale proud tě bude strhávat a cesta ti vezme spoustu sil a času. Můžeš však také obhlédnout řeku, využít zkušeností s prouděním vody, nechat se unášet po proudu a pouze na několika vhodných místech správně zabrat a zalomit pádlo. Ta místa, kde máš zabrat, jsou právě pákové body. Malá změna, velké následky.

M: Zní to trochu jako reklama na americkou manažerskou literaturu s taoistickou příchutí.

S: I tak se to dá samozřejmě pojmout. Já ti to zkusím vysvětlit pomocí pojmů, které jsme používali při modelování, a dám ti pár příkladů. Co si z toho odneseš, už je na tobě.



Obr. 17.1: Pákový bod: malá změna, velké následky. „Dejte mi dostatečně dlouhou páku a pevný bod a pohnu světem.“ (Archimedes)

17.1 Hierarchie pákových bodů

V této kapitole využíváme způsob myšlení a pojmy, které jsme probrali dříve, výklad je jinak zcela neformální. Vrátime se zpět k obecným úvahám o komplexních systémech, jimiž jsme začínali, a pomalu uzavíráme cyklus, respektive spirálu, z obr. 1.2 v úvodní kapitole. V této kapitole již nebudeme mluvit o žádném konkrétním modelovacím přístupu, nicméně pro dobré pochopení tématu je velmi užitečné mít zkušenosti s modelováním a znát pojmy z oblasti systémového myšlení (např. zpětné vazby, parametry, zásobníky).

Budeme se zabývat především konceptem pákového bodu – místa v systému, kde malá změna může mít velké následky (obr. 17.1). Taková místa nás pochopitelně velmi zajímají, protože představují efektivní nástroj, jak ovlivňovat chování systému. Na jejich hledání však neexistuje žádný zaručený návod – vždy je potřeba důkladně analyzovat konkrétní systém, k čemuž se nám hodí modelování a systémové myšlení. Tyto schopnosti a zkušenosti nám také mohou pomoci zamyslet se nad pákovými body obecně. Univerzální zaručený návod na hledání pákových bodů sice neexistuje, nicméně pár principů formulovat lze.

Pěkný náhled na takové užitečné principy dává „hierarchie pákových bodů“ od Donelly Meadowsové, významné protagonistky systémového myšlení a modelování. Jde o seznam prvků systému seřazený do hierarchie podle toho, jak velký pákový potenciál jednotlivé prvky mají. Čím výše jsme v hierarchii, tím výraznější potenciální „páku“ daný prvek představuje.

Celkový přehled hierarchie pákových bodů dává tabulka 17.1. Komentář k jednotlivým bodům projdeme v rostoucím pořadí efektivnosti. Při výkladu hierarchie zmíníme namátkově příklady z různých oblastí, dále v kapitole se pak podíváme na souhrnné příklady.

Tabulka 17.1: Hierarchie pákových bodů (podle Meadows, 1999).

- 1 moc přesahovat paradigmatata
- 2 paradigmatata
- 3 cíle systému
- 4 moc měnit, vyvíjet a samo-organizovat strukturu
- 5 pravidla systému
- 6 struktura informačních toků
- 7 síla pozitivních zpětných vazeb
- 8 síla negativních zpětných vazeb
- 9 doba zpoždění
- 10 struktura materiálních zásobáren a toků
- 11 velikosti zásobníků
- 12 parametry

12. Parametry. Parametry určují kvantitativní vlastnosti procesů v systému. Parametry často přitahují největší pozornost při úvahách o ovlivňování systémů (viz například úroková míra, minimální plat či výdaje na výzkum), málokdy však dokáží chování systému výrazně změnit. Výjimku tvoří případy, kdy parametr přímo souvisí s některým z význačnějších pákových bodů.

11. Velikosti zásobníků. Zásobníky jsou stabilizující prvky systému – místa v systému, kde se něco hromadí. Pro chování systému je důležitá velikost zásobníků relativně k velikosti procesů, které tyto zásobníky mění. Malé zásobníky vedou k nestabilitě, velké zásobníky k nepružnosti (viz například množství zásob ve skladě relativně k objemu zakázek). Stabilita a pružnost jsou velmi důležité vlastnosti systémů, takže velikost zásobníků výrazně ovlivňuje celkové chování. Nicméně velikost zásobníků se většinou velmi těžko mění, takže není výrazným pákovým bodem.

10. Struktura materiálních zásobáren a toků. Fyzická struktura systému opět výrazně ovlivňuje celkové chování systému, nicméně změna existujících toků je opět velmi náročná, a tedy málokdy bývá pákovým bodem. Jako příklad uveďme dopravní síť Maďarska, která je silně centralizovaná okolo Budapešti. Tato struktura výrazně ovlivňuje celý dopravní systém a nelze ji jednoduše změnit.

9. Doba zpoždění. Systémy v sobě obsahují celou řadu zpoždění a tato zpoždění mohou výrazně ovlivňovat chování systému. Typickým příkladem je sprcha – pokud sprcha na změnu teploty reaguje rychle, snadno si nastavíte teplotu a osprchujete se, pokud má sprcha zpoždění, sprchování většinou probíhá jako neustálé střídání příliš studené a příliš horké vody. Ze závažnějších příkladů uveďme poptávku a výrobu elektřiny. Protože výstavba elektráren trvá mnoho let, je v systému velké zpoždění, které způsobuje oscilace mezi přebytkem a nedostatkem. Doba zpoždění stále patří k prvkům systému, které sice hrají důležitou roli, ale je těžké je měnit. Většinou se setkáváme s tlakem na zkrácení zpoždění. Bývá ovšem snazší zpomalit vlastní systém než zkrátit zpoždění. Zkrácení zpoždění navíc nemusí vést k žádanému efektu stabilizace systému, ale pouze k oscilacím s vyšší frekvencí – například zkrácení zpoždění

při finančních transakcích nevede ke stabilnějšímu finančnímu systému, ale k systému s rychlejšími výkyvy.

8. *Síla negativních zpětných vazeb.* O významu zpětných vazeb a jejich roli v komplexních systémech jsme se zmiňovali mnohokrát. Přítomnost a síla zpětných vazeb tedy výrazně ovlivňuje chování systémů a na rozdíl od dříve uvedených prvků jde často i docela dobře měnit. Síla negativní zpětné vazby, tedy schopnost udržovat systém u cílového stavu, závisí například na přesnosti měření, rychlosti odezvy a na její efektivnosti. Příklady negativních zpětných vazeb a prvků, které zeslabují jejich sílu: volný trh a dotace, řízení auta a alkohol, demokracie a centralizovaná média.

7. *Síla pozitivních zpětných vazeb.* Pozitivní zpětné vazby mohou vést k nestabilitě nebo mohou vytvářet nové struktury. Většinou jsou vyváženy negativními cykly, protože však změna síly pozitivního cyklu má výraznější dopad než změna síly negativního cyklu, jde o významnější pákový bod. Typickým příkladem je populační dynamika: pozitivní zpětnou vazbu zde ovlivňuje především porodnost, negativní zpětné vazby tvoří například hladomory či války.

6. *Struktura informačních toků.* Struktura informačních toků má na chování systémů často srovnatelný dopad jako struktura materiálních toků. Na rozdíl od materiálních toků se ovšem struktura informačních toků daleko snáze mění, a proto jde o výrazně důležitější pákový bod. Uvedme pro ilustraci dva příklady, kdy přidání nového čistě informačního zpětnovazebního cyklu výrazně mění chování systému. Prvním příkladem je zástavba rodinných domů, které byly identické, pouze některé z nich měly měřič elektrické spotřeby ve sklepech a některé na chodbě. Domy s měřičem na chodbě měly v průměru o 30 procent nižší spotřebu elektřiny. Druhým příkladem je americký zákon „Toxic Release Inventory“, který přikazoval firmám hlásit množství vypouštěných škodlivých látek. Zákon nepředepisoval žádné postihy, požadoval pouze informovanost, a i tak vedl ke snížení škodlivých emisí o 40 procent.

5. *Pravidla systému.* Komplexní systémy se skládají z mnoha dílčích komponent. Tyto komponenty jsou vesměs autonomní a nikdo je neřídí přímo. Komponenty se však řídí určitými pravidly. I drobná změna pravidel může mít velké následky. Co se stane, když odeberete z modelu hejna jedno pravidlo? Co se stalo, když Gorbačov zavedl glasnost a perestrojku? Co by se stalo, kdyby učitelé neznámkovali žáky, ale celou třídu? Pravidla systému jsou významný pákový bod.

4. *Moc měnit, vyvíjet a samo-organizovat strukturu.* Komplexní systémy mají schopnost samo-organizovat se a vyvíjet nové struktury, viz například evoluce a vznik nových druhů, imunitní systém a obranné reakce proti novým nemocem, společnost a vznik nových společenských uspořádání, věda a nové objevy. Schopnost samo-organizace závisí především na diverzitě. Kde je málo druhů, těžko dochází k evoluci. Kde je málo odlišných názorů, těžko dochází ke společenskému vývoji a novým objevům.

3. *Cíle systému.* Cíle systému jsou velmi vysoký pákový bod, protože z cílů systému se odvozuje všechno dříve uvedené. Pokud je cílem systému ovládnout svět, jsou tomu přizpůsobovány všechny zpětné vazby, pravidla i schopnost samo-organizace systému. Představte si rozdíly mezi systémy s cíli „ekonomický růst“, „naprostá sociální rovnost“, „trvale udržitelný rozvoj“. Změnit cíl existujícího systému není sa-

možřejmě úplně snadné, ale obzvláště ve chvíli, kdy vzniká nový systém, jsou cíle systému velmi silný pákový bod.

2. *Paradigmata*. Paradigmata systému jsou „zřejmé pravdy“, kterým věříme a nepřemýšlíme o nich. Paradigmata se většinou mění pomalu a postupně, nicméně i hodně malá změna na úrovni paradigmatu může mít velký vliv na celý systém. Paradigmata systému jsou důležitějším pákovým bodem než cíle, protože cíle se z nich (často nevědomky) odvozují. Pokud přijmeme jako paradigma egyptské náboženství, je stavba pyramid rozumným cílem a otrokářství nezbytným pravidlem. V průběhu historie lidé měli mnoho různých, vzájemně naprosto nekompatibilních paradigmat, o kterých byli přesvědčeni, že jsou správná. Ale to je historie. Naše současné paradigma, které zahrnuje například nadřazenost člověka ostatním druhům či klíčový význam demokracie, lidských práv a volného trhu, je už určitě správně. To je přece jasné. O tom se ani nemusí přemýšlet.

1. *Moc přesahovat paradigmata*. Na nejvyšším stupni hierarchie pákových bodů uvádí Donella Meadowsová moc přesahovat paradigmata, schopnost udržet se nezávislý na paradigmatech, uvědomit si, že žádné paradigma nejspíš není „správné“, a pokud je, tak, že znalost tohoto paradigmatu přísluší jiným bytostem než lidem.

Na závěr připojme také upozornění, které uvádí autorka popsaného seznamu. Čím výše v hierarchii pákových bodů se nacházíme, tím větší dopad mohou mít malé změny, ovšem také tím více bude systém svou setrvačností jakýmkoliv změnám odolávat. I velmi drobná změna paradigmatu může mít dalekosáhlé důsledky, ale změnit paradigma bytí jediného člověka je dosti náročné. Stříbrné kulky a magická hesla neexistují. Znalost hierarchie pákových bodů nám může pomoci, ale ovlivňování komplexních systémů je prostě složitá práce.

Souvislosti: Tato část, včetně zmíněných příkladů, vychází z článku Donelly Meadowsové (1999). Jde o stručný, čtivě napsaný a na internetu snadno dostupný článek, takže čtenáři, kterého téma zaujalo, silně doporučujeme přečíst si jej kompletně.

17.2 Paretův princip

S pákovými body úzce souvisejí mocinné zákony, na které jsme narazili v 9. kapitole a jež jsou všeobecně známy spíše pod názvem „Paretův princip“ nebo „princip 80/20“. Název se odvozuje od pozorování ekonoma Vilfreda Pareta, který na konci 19. století poznamenal, že 80 % majetku v Itálii je vlastněno 20 % nejbohatších obyvatel. Později se ukázalo, že tento princip platí nejen pro Itálii, ale i pro další země, a nejen pro rozdělení bohatství, ale i pro mnoho dalších prvků běžného života: 80 % zakázek pochází od 20 % zákazníků, 80 % času zabere 20 % práce, 80 % času používáme 20 % našeho oblečení, 80 % času trávíme s 20 % svých známých.

Paretův princip má samozřejmě vždy jen přibližnou povahu, přesná čísla závisejí na konkrétním systému. Společným prvkem pro různé příklady je silná nerovnoměrnost rozdělení, a tedy existence míst v systému (oněch 20 %), která mají na chování

systemu velký vliv (protože ovlivňují 80 % výstupů). Jsme tedy opět u pákových bodů – míst v systému, kde malá změna může způsobit velké následky.

Paretův princip je populární v „manažerské literatuře“, protože dává zdání, že můžeme pákové body snadno najít a snadno použít pro rychlé zlepšení chování systému. Paretův princip je ovšem pouze popisný – říká nám, co se děje, ale nikoliv proč. Navíc také říká pouze to, že *nějakých* 20 % systému má za následek *nějakých* 80 % výsledků. Ale která část systému to přesně je? Jak dosáhnout změny?

V jednoduchých případech nám tato popisná charakteristika stačí. Když si uvědomím, že 80 % času používám 20 % svého oblečení, docela snadno dokáži zjistit, o které oblečení jde, a mohu přeorganizovat způsob ukládání oblečení tak, aby často používané oblečení bylo snadno po ruce. Avšak u systémů, které jsou složitější a kde změna může mít zásadnější dopad, je použití principu náročnější. Výskyt principu 80/20 je většinou způsoben zpětnými vazbami. Abychom pochopili fungování zpětných vazeb v systému, potřebujeme pochopit celkovou strukturu systému. A především – abychom mohli použít pákových bodů sídlících v „20 %“, musíme mít jasno v tom, co vlastně je cílem systému. Není příliš užitečné zvládnout lézt po žebříku rychleji, když jej máte opřený o špatnou zeď.

Paretův princip sám o sobě nám tedy příliš nepomůže v praktickém ovlivňování systému. K tomu je potřeba uvažovat o celém systému, přemýšlet o celé hierarchii možných pákových bodů. Paretův princip je však užitečný v tom, že nás učí všimnout si vnějších projevů pákových bodů, a tím nám dodává víru v jejich existenci a sílu k jejich hledání.

17.3 Příklady

Nyní uvedeme konkrétní příklady ilustrující uvedené principy. Za povšimnutí stojí, že pro všechny příklady je společné, že naše pozornost je výrazně věnována pákovým bodům s nízkým vlivem – typický příklad principu 80/20. Příklady mají také společné to, že silným pákovým bodem je rozmyšlení cílů – zamyšlení se nad otázkou „Proč to vlastně dělám?“

Osobní život

Co jsou důležité pákové body v našem životě?

- Paradigmata: Čemu věřím (náboženství, fungování světa, základní životní hodnoty)?
- Cíle: O co mi v životě jde? Chci se bavit a užívat si? Chci se toho co nejvíc dozvědět a být co nejmoudřejší? Chci být prospěšný svému okolí? Chci zachránit svět? Chci ovládat co nejvíc lidí?
- Pravidla: Chovám se poctivě, nebo pragmaticky? Řídím se aktuálními společenskými normami, zákony? Která společensky uznávaná pravidla jsem ochoten překračovat a proč?
- Informační toky: Odkud získávám informace? Co čtu, sleduji? S kým se stýkám?

Jak často se však zabýváme těmito důležitými pákovými body? Většinou věnujeme daleko více pozornosti bodům z druhého konce seznamu – parametrům a materiálním tokům. Kolik vydělávám, kde bydlím, jaké mám věci. Což o to, peníze a ubytování jsou potřebné, ale drobná změna ve velikosti příjmu má menší potenciál změnit život než ujasnění si toho, čemu vlastně věřím.

Příprava jednorázové akce či přednášky

Představme si jednorázovou akci, kterou máme zorganizovat – může jít o vědeckou konferenci, sportovní závody nebo tábor pro děti. Co jsou důležité pákové body?

- Cíle akce: Proč se akce vůbec koná? Čeho by akce měla dosáhnout? Jaký by měl být žádaný výstup?
- Schopnost samo-organizace: Jaké bude složení organizátorského týmu?
- Pravidla: Jsou pravidla v souladu s cíli? Podporují pravidla spolupráci mezi účastníky akce, nebo spíš soutěž?
- Informační toky a zpětné vazby: Jak budou proudit informace mezi organizátory a účastníky? Jakým způsobem se akce bude přizpůsobovat účastníkům?

Jak vypadá taková typická příprava akce ve skutečnosti? Nad cíli akce často nikdo nepřemýšlí nebo se použijí obecné fráze, které nikomu nic neříkají. Organizátorský tým se poskládá z lidí, co jsou zrovna po ruce. Pravidla se nastaví jako tradičně – že tato tradiční pravidla vznikla za zcela odlišných podmínek, nikdo neřeší. Zato se intenzivně řeší parametry, materiální zásobárny a toky – jaký bude přesný časový harmonogram, jestli bude dostatek chlebičků, kudy povede trasa závodu a jaké bude pořadí slov na letáčku.

Podobně tomu je při přípravě přednášky. Velký vliv má dobré rozmyšlení cílů přednášky (co by si měli posluchači odnést?), určení pravidel (přednes bez vyrušování, nebo interaktivní multimediální show), informační toky a zpětné vazby (reaguje přednášející na zpětnou vazbu od posluchačů, nebo jede striktně podle připraveného průběhu?). Na tyto otázky však málokdy dojde, protože je potřeba vyzkoušet nový software pro tvorbu prezentací, připravit dynamické animace, trochu upravit třetí obrázek a zprovoznit laserové ukazovátka.

Politika státu

Na závěr se vraťme k systému, ke kterému jsme zmínili několik příkladů průběžně (na rozdíl od předchozích příkladů zde autor musí přiznat, že s řízením tohoto systému nemá žádné zkušenosti). Co jsou důležité pákové body ve fungování státu?

- Paradigmata: role náboženství, vlastenectví, základní životní hodnoty, rasové předsudky.
- Cíle: ekonomický růst, trvalá udržitelnost, sociální blahobyt, svoboda jednotlivce.
- Schopnost samo-organizace: způsob řízení státu (mechanismus voleb).

- Pravidla: zákony.
- Informační toky: transparentnost úřadů, přístup občanů k informacím.

Příkladem informačního toku, kterému se dostává vysoké pozornosti a figuruje i v cílech systému (byť třeba ne oficiálně), je definice hrubého domácího produktu (HDP). Definice HDP není pevně danou objektivní ideální entitou, současná definice má naopak mnoho známých nedostatků, například spotřebovávání neobnovitelných zdrojů a nehody na silnicích paradoxně přispívají k růstu HDP. Změna definice HDP tak představuje vysoký pákový bod ve fungování státu.

Bohužel změně definice HDP, stejně jako ostatním z výše uvedených témat, se mediální pozornosti příliš nedostává. Pozornost se většinou opět soustředí na parametry a materiální toky: jestli se má platit 30 korun u lékaře, jaká bude přesně velikost státního deficitu a jestli se nová silnice postaví zleva, nebo zprava. Jestli je žádoucí mít co nejvíc silnic, už se neřeší. To je přece jasné.

17.4 Shrnutí

- Způsob myšlení, který se učíme při modelování, lze použít i v běžném životě, aniž bychom vytvářeli formální modely.
- Pákové body jsou místa v komplexním systému, kde malá změna může způsobit velké následky.
- Nejúčinnější pákové body leží v cílech systému, jeho struktuře a pravidlech.
- Většinu pozornosti však často věnujeme prvkům systému, které mnoho nezmění anebo které je velmi obtížné změnit, jako jsou dílčí parametry, struktura materiálních toků.

Závěr

*A dej mi sílu unésti
všechno co změnit nemám sil
Odvahu abych to nač stačím
na tomto světě pozměnil
A také moudrost abych znal
a od sebe to rozeznal (J. Skácel)*

Skácelova básnička má název „Modlitba stará – stará!“ Opravdu jde o přání, které lidstvo doprovází odpradáвна a jež můžeme v různých obměnách objevit v mnoha příbězích a citátech. Modelování s použitím počítačů můžeme vnímat jako jeden z moderních kroků na cestě při hledání síly, odvahy a moudrosti.

Dobré modely nám pomáhají hlavně hledat moudrost, přičemž opravdu jde především o moudrost, a nikoliv o chytrost nebo vědomosti. Hlavní přínos zkušeností s modelováním není v získaných vědomostech, které bychom mohli přímo využít, ale daleko více v pohledu, jaký nám otevírá na svět. Díky modelům můžeme vidět zajímavé problémy tam, kde jsme předtím neviděli nic zvláštního, a spatřit náznaky řešení tam, kde jsme dosud viděli pouze problémy.

Zkušenost s modelováním nás také učí pokoře, což je jeden z klíčových předpokladů moudrosti. Díky modelům víme, jak obtížné může být pochopit fungování i velmi jednoduchého systému. Při vytváření vlastních modelů velmi rychle zjišťujeme, že i ve věcech, o kterých jsme si mysleli, že jsou nám úplně jasné, máme docela zmatek. Díky těmto zkušenostem můžeme být méně náchylní k příliš zjednodušujícím interpretacím světa kolem nás a k chybám pramenícím z těchto nepatřičných zjednodušení. Modelování nás nepřímou vedou k uznání omezenosti vlastního chápání světa.

Pokorný přístup však neznamená, že se spokojíme s konstatováním „svět je složitý, vůbec mu nerozumíme, nedokážeme říct, co naše akce způsobí, radši nebudeme nic dělat“. Nejde nic nedělat. Absence aktivní akce je také rozhodnutím. Absence změny znamená, že budeme dál pokračovat v tom, v čem doposud, a to je málokdy zcela optimální řešení.

Potřebujeme mít odvalu volit si svoje akce a sílu vykonávat je. I v tom nám mohou pomoci modely. S jejich pomocí se můžeme důkladněji zamyslet nad různými

možnosti, dobře rozvážit výběr svých akcí, získat v ně důvěru a o to rozhodněji je pak vykonávat.

Modelování a simulace s použitím výkonných počítačů tvoří velmi silný nástroj, ale koneckonců je to jen nástroj. Záleží pouze na nás, na lidech, jak tento nástroj použijeme. Sílu, odvahu a moudrost nám sám o sobě tento nástroj nedá.

Literatura

Tučně zvýrazněné knihy jsou obzvláště doporučené. Vybrané zdroje (vesměs ty, které mají nejužší souvislost s touto knihou) jsou stručně okomentovány.

Adams, J. (1995). *Risk*. UCL Press.

Albert, R., Barabási, A. L. (2002). *Statistical Mechanics of Complex Networks*. *Reviews of Modern Physics*, 74(1), 47–97.

Albert, R., Jeong, H., Barabási, A. L. (2000). *Error and Attack Tolerance of Complex Networks*. *Nature* 406, 378–382.

Anderson, J. R., Bothell, D., Byrne, M. D., Douglass, S., Lebiere, C., Qin, Y. (1994). *An Integrated Theory of the Mind*. *Psychological Review*, 111(4), 313–341.

Arthur, W. B. (1990). *Positive Feedbacks in the Economy*. *Scientific American*, 262(2): 80–85.

Arthur, W. B. (1994a). *Inductive Reasoning and Bounded Rationality*. *The American Economic Review*, 84(2), 406–411.

Arthur, W. B. (1994b). *Increasing Returns and Path Dependence in the Economy*. University of Michigan Press.

Arthur, W. B. (1996). *Increasing Returns and the New World of Business*. *Harvard Business Review*, 74: 100–111.

Arthur, W. B., Holland, J. H., LeBaron, B., Palmer, R., Tayler, P. (1997). *Asset Pricing Under Endogenous Expectations in an Artificial Stock Market*. *The Economy as an Evolving Complex System II*, Reading, MA: Addison-Wesley.

Axelrod, R. (1985). **Evolution of Cooperation**. Basic Books.

Knihy popisuje turnaje ve hře Dilema vězně a z nich vyplývající pozorování a úvahy.

Axelrod, R. (1997a). **The Complexity of Cooperation**. Princeton University Press.

Knihy volně navazuje na *Evolution of Cooperation*, popisuje rozšíření hry Dilema vězně a podobné hry a analýzy využívající modelování a simulaci.

Axelrod, R. (1997b). *Advancing the Art of Simulation in the Social Sciences*. *Complexity*, 3(2), 16–22.

Barabási, A. L. (2002). **Linked: The New Science of Networks**. Perseus Books Group. (*V pavučině sítí*, Paseka, 2005)

Populárně psaná kniha o nové „vědě sítí“. Uvádí zejména hodně příkladů komplexních sítí, diskutuje typické vlastnosti těchto sítí a odlišnosti od náhodných grafů, popisuje vývoj „vědy sítí“. Psáno velmi čtivě.

- Barnes, B., Fulford, G. R. (2002). *Mathematical Modelling with Case Studies. A Differential Equation Approach Using Maple*. Taylor & Francis.
- Bar-Yam, Y. (2003). *Dynamics of Complex Systems*. Westview Press.
- Bornholdt, S., Schuster, H. G. eds. (2003). *Handbook of Graphs and Networks: From the Genome to the Internet*. Wiley-VCH.
- Bower, J. M., Bolouri, H. eds. (2001). *Computational Modeling of Genetic and Biochemical Networks*. The MIT Press.
- Bruner, J. S., Postman, L. (1949). *On the Perception of Incongruity: A paradigm*. *Journal of Personality*, 18, 206–223.
- Camazine, S., Deneubourg, J.-L., Franks, N. R., Sneyd, J., Theraulaz, G., Bonabeau, E., eds. (2003). **Self-organization in biological systems**. Princeton University Press.
 Kniha začíná relativně stručným obecným úvodem o modelování a samoorganizaci v přírodních systémech. Zbytek knihy je věnován konkrétním případovým studiím, zejména sociálnímu hmyzu (mravenci, včely, vosy).
- Centola, D., Wilensky, U., Mckenzie, E. (2000). *A Hand-on Modeling Approach to Evolution: Learning about the Evolution of Cooperation and Altruism Through Multi-Agent Modeling – The EACH Project*. International Conference of the Learning Sciences.
- COMET Program (2006). *Understanding NWP Models and Their Processes*. University Corporation for Atmospheric Research.
<http://www.meted.ucar.edu/nwp/course>
- Dawkins, R. (1976). **The Selfish Gene**. Oxford University Press. (*Sobecký gen*, Mladá fronta, 2003)
 Známá, populární, mírně kontroverzní kniha. Pohled na evoluci očima genu – jak sobecké chování genů (snaha co nejvíce se rozšířit) může vést například k altruistickému chování.
- Deaton, M. L., Winebrake, J. J. (1997). *Dynamic Modeling of Environmental Systems*. Springer.
- Del Valle, S. Y., Kubicek, D., Mniszewski, S. M., Riese, J. M., Romero, P. R., Smith, J. P., Stroud, P. D., Sydoriak, S. J. (2006). *EpiSimS Los Angeles Case Study*. Los Alamos National Laboratory.
- Ellner, S. P., Guckenheimer, J. (2006). *Dynamic Models in Biology*. Princeton University Press.
- Epstein, J. M. (2006). **Generative Social Science**. Princeton University Press.
 Kniha začíná úvodem do modelování s agenty zaměřeným především na použití v sociálních vědách a dále obsahuje několik zajímavých případových studií.
- Epstein, J. M., Axtell, R. (1996). *Growing Artificial Societies: Social Science from the Bottom Up*. Brookings Institution Press.
- Fisher, J., Piterman, N., Hubbard, E. J. A., Stern, M. J., Harel, D. (2005). *Computational Insights into Caenorhabditis Elegans Vulval Development*, *Proceedings of the National Academy of Sciences*, 102(6): 1951–1956.
- Flake, G. (2000). **Computation Beauty of Nature**. The MIT Press.
 Kniha o různém použití výpočetních modelů inspirovaných přírodou: fraktály,

chaos, vyčíslitelnost, adaptace, emergentní chování a souvislosti mezi nimi. Některé kapitoly se přímo dotýkají modelování a simulace, některé jsou trochu vzdálenější. Každopádně velmi pěkně pojatá kniha.

Flegr, J. (2006). *Zamrzlá evoluce*. Academia.

Populárně psaná kniha o tom, jak (ne)funguje evoluce. Obsahuje mimo jiné slovní popis několika modelů.

Gell-Mann, M. (2002). *The Quark and the Jaguar: Adventures in the Simple and the Complex*. Owl Books.

Gilbert, N. (2008). *Agent-Based Models*. Sage Publications.

Stručný a výstižný úvod do modelování pomocí agentů zaměřený především na aplikace v sociálních vědách.

Gilbert, N., Troitzsch, K. G. (2005). *Simulation for the Social Scientist*. Open University Press.

Přehled různých modelovacích formalismů a metod simulace. Každou metodu uvádí pouze stručně a vysvětluje ji na příkladě. Směřováno k aplikacím v sociálních vědách.

Gladwell, W. (2000). *The Tipping Point: How Little Things Can Make a Big Difference*. Little, Brown and Company. (*Bod zlomu: O malých příčinách s velkými následky*, Dokořán, 2006)

Populárně naučná kniha o tom, jak malé změny mohou mít velké následky, konkrétně v kontextu sociálních epidemií (šíření modních trendů, informací, postojů).

Gordon, D. (1999). *Ants at work*. Free Press.

Grimm, V., Railsback, S. F. (2005). *Individual-based Modelling and Ecology*. Princeton University Press.

Obecný úvod o modelování (pomocí agentů) následovaný konkrétními příklady z oblasti ekologie, zejména ekologie živočichů. Kniha obsahuje rovněž obecné metodické rady.

Hamilton, W. D., Axelrod, R., Tanese, R. (1990). *Sexual Reproduction as an Adaptation to Resist Parasites (A Review)*. Proceedings of the National Academy of Sciences, 87(9): 3566–3573.

Hardin, G. (1986). **The Tragedy of Commons**. Science, 162 (3859), 1243–1248.

Holland, J. H. (1995). *Hidden Order: How Adaptation Builds Complexity*. Addison Wesley.

Kniha se zabývá modelováním adaptace, zejména detailním popisem formalismu klasifikačních systémů a ukázkou jeho aplikace.

Hutchins, E., Hazlehurst, B. (1995). *How to Invent a Lexicon: the Development of Shared Symbols in Interaction*. Artificial Societies: The Computer Simulation of Social Life, 157–189, UCL Press.

Ilachinski, A. (2001). *Cellular Automata*. World Scientific.

Detailní technický přehled buněčných automatů.

IPCC (2007). *Climate Change 2007. The Fourth Assessment Report of the United Nations Intergovernmental Panel on Climate Change*.

<http://www.ipcc.ch/>

- Johnson, S. (2001). *Emergence: The Connected Lives of Ants, Brains, Cities, and Software*. Penguin books.
- Populární výklad emergentního chování – jak se z lokálních pravidel a interakcí vypořádávají nové chování na úrovni celku. Příklady, příběhy, netechnické, čtivé.
- Kauffman, S. (2000). *Investigations*, Oxford University Press. (*Čtvrtý zákon*, Pašek, 2004)
- Kniha s podtitulem „Cesty k obecné biologii“, ve které autor (dostí spekulativně) uvažuje o životě a principech jeho fungování. Ve výkladu je použita celá řada modelů.
- Kermack, W. O., McKendrick, A. G. (1927). *A Contribution to the Mathematical Theory of Epidemics*. Proc. of the Royal Society of London. Series A, 115: 700–721.
- Kitano, H. (2001). *Foundations of Systems Biology*. MIT Press.
- Kitano, H. (2002a). *Computational Systems Biology*. Nature 420(6912): 206–210.
- Kitano, H. (2002b). *Systems Biology: a Brief Overview*. Science 295(5560): 1662–1664.
- Kleinberg, J. M. (2002). *Navigation in a Small World*. Nature, 406(6798): 845.
- Krebs, Ch. J. (2001). *Ecology*, Addison Wesley Longman.
- Pěkná učebnice základů ekologie (především populační dynamiky), zmiňuje mimo jiné hodně matematických modelů.
- Kuhn, T. (1962). *The Structure of Scientific Revolutions*. University of Chicago Press (*Struktura vědeckých revolucí*, Oikoymenth, 1997)
- Langton, C. G. (1984). *Self-reproduction in Cellular Automata*. Physica D: Nonlinear Phenomena, 10(1–2), 135–144.
- Leiser, D. (1983). *Children's Conceptions of Economics – The Constitution of a Cognitive Domain*. Journal of Economic Psychology, 4(4): 297–317.
- Lenton, T. M, Lovelock, J. E. (2001). *Daisyworld Revisited: Quantifying Biological Effects on Planetary Self-regulation*. Tellus Series B – Chemical and Physical Meteorology, 53(3): 288–305.
- Mařík, V., Štěpánková, O., Lažanský, J. a kol. (1993, 1997, 2001, 2003) *Umělá inteligence I–IV*. Academia.
- Miller, H., Page, S. E. (2007). *Complex Adaptive Systems: An Introduction to Computational Models of Social Life*. Princeton University Press.
- Čtivá kniha zaměřená především na modelování pomocí agentů v oblasti sociálních systémů.
- Miller, J. H. (1998). *Active Nonlinear Tests (ANTs) of Complex Simulation Models*. Management science 44(6): 820–830.
- Mitchell, M. (2009). *Complexity: A Guided Tour*. Oxford University Press.
- Mitteldorf, J., Wilson, D. S. (2000). *Population Viscosity and the Evolution of Altruism*. Journal of Theoretical Biology, 204(4): 481–496.
- Meadows, D. H. (1999). **Leverage Points: Places to Intervene in a System**. The Sustainability Institute.
- Netechnický článek popisující „pákové body“, tj. místa v systému, kde malý zásah může mít velký efekt.

- Meadows, D. H., Meadows, D. L., Randers, J. (1993). *Beyond the limits*. Chelsea Green Publishing Company. (*Překročení mezí*, Argo, 1995)
- Meadows, D. H., Meadows, D. L., Randers, J. (2004). **Limits to growth: The 30-year update**. Chelsea Green Publishing Company.
 Knihy o modelování interakce lidské civilizace s limity planety. Prezentace modelu World3 a jeho analýzy pomocí simulace, diskuze důsledků a doporučení pro budoucí vývoj.
- Newman, M., Barabási, A. L., Watts, D. J., eds. (2006). *The Structure and Dynamics of Networks*. Princeton University Press.
- Nooy, W. de, Mrvar, A., Batagelj, V. (2005). *Exploratory Social Network Analysis with Pajek*. Cambridge University Press.
- Nordhaus, W. (1994). *Expert Opinion on Climatic Change*. American Scientist 82(1): 45–51.
- Osborne, J. M., Rubinstein, A. (1994). *A Course in Game Theory*. The MIT Press.
- Peitgen, H.-O., Jurgens, H., Saupe, D. (1992). *Chaos and Fractals: New Frontiers of Science*. Springer-Verlag.
 Rozsáhlá kniha poskytující relativně detailní úvod do studia fraktálů a chaosu. Přestože je docela technická, je poměrně čtivá a má spoustu pěkných obrázků.
- Ray, T. S. (1991). *An Approach to the Synthesis of Life*. Artificial Life II, Santa Fe Institute.
- Reynolds, C. W. (1987). *Flocks, Herds and Schools: A Distributed Behavioral Model*. Proc. of Computer graphics and interactive techniques, 25–34, ACM.
 Mnoho doplňujících informací a navazujících článků lze nalézt na internetové adrese <http://www.red3d.com/cwr/boids/>.
- Resnick, M. (1997). **Termites, Turtles, and Traffic Jams**. The MIT Press.
 Útlá kniha o decentralizovaném myšlení. Velká část knihy spočívá v diskuzi různých příkladů (mravenci, termiti, zácpy). Psáno čtivě, pedagogicky, zajímavě.
- Russell, S., Norvig, P. (2009). *Artificial Intelligence: A Modern Approach*. Prentice Hall; 3 edition.
- Samuelson, P. A., Nordhaus, W. D. (1991). *Ekonomie*. Svoboda.
- Sangalli, A. (1998). *The Importance of Being Fuzzy*. Princeton University Press.
 Populárně psaná kniha o „soft computing“, autor popisuje především počítání s fuzzy množinami, neuronové sítě, genetické algoritmy a srovnává tyto techniky s klasickými výpočetními metodami.
- Schelling, T. C. (1969). *Models of Segregation*. The American Economic Review, 59(2): 488–493.
- Sterman, J. D. (2000). *Business Dynamics: Systems Thinking and Modeling for a Complex World*. McGraw-Hill/Irwin.
 Rozsáhlá kniha vysvětlující základy systémového myšlení a systémového modelování. Zaměřena zejména na aplikaci v marketingu, obchodování, podnikání. Psána odpovídajícím stylem (tj. zejména hodně ilustrativních příkladů a diagramů, málo matematiky).
- Still, G. K. (2000). *Crowd Dynamics*. PhD Thesis, University of Warwick.
- Storch, D., Mihulka, S. (2000). *Úvod do současné ekologie*. Portál.

- Strogatz, S. H. (2001). *Exploring Complex Networks*. Nature 410 (6825): 268–276.
- Sun, R., ed. (2008). *The Cambridge Handbook of Computational Psychology*. Cambridge University Press.
- Szallasi, Z., Stelling, J., Periwál, V., eds. (2006). *System Modeling in Cellular Biology*. The MIT Press.
- Šíma, J., Neruda, R. (1996). *Teoretické otázky neuronových sítí*. MatfyzPress.
- Tesfatsion, L., Judd, K. L. (2006). *Handbook of Computational Economics. Volume 2: Agent-based Computational Economics*. Elsevier.
- Rozsáhlá příručka obsahující příspěvky, vesměs spíše technicky psané, týkající se využití modelování s agenty v ekonomii.
- Wason, P., Johnson-Laird, P. (1972). *Psychology of Reasoning: Structure and Content*. Harvard university Press.
- Watson, A. J., Lovelock, J. E. (1983). *Biological Homeostasis of the Global Environment: the Parable of Daisyworld*. Tellus B, 35(4): 284–289.
- Watts. D. (2003). *Small Worlds: The Dynamics of Networks between Order and Randomness*, Princeton University Press.
- Technická kniha představující jeden z modelů sítí (model malého světa) a diskutující studie s tímto modelem.
- Weinberg, G. M. (1975). *An Introduction to General Systems Thinking*, Dorset House Publishing.
- Klasický úvod do systémového myšlení. Psán populárně s řadou slovně vysvětlených příkladů.
- Wilensky, U. (1998). **NetLogo Models Library**. Center for Connected Learning and Computer-Based Modeling, Northwestern University.
- Bohatá sbírka modelů s agenty, která je volně dostupná na internetu. Modely jsou okomentovány a doprovázeny odkazy na další zdroje.
- Wilson, R. A., Keil, F. C., eds. (1999). *The MIT Encyclopedia of the Cognitive Sciences*. The MIT Press.
- Wolfram, S. (2002). *New Kind of Science*. Wolfram Media.
- Rozsáhlá kniha na téma „jak jednoduchá pravidla mohou vést k složitým jednáním“. Zabývá se především buněčnými automaty. Kniha je mimo jiné známá svými mírně přehnanými tvrzeními o „novém druhu vědy“ a egocentrickým tónem autora.
- Wooldridge, M. (2009). *An Introduction to MultiAgent Systems*. John Wiley & Sons.

A Slovníček pojmů

Literatura k tématu knihy je dostupná většinou pouze v angličtině, proto zde uvádíme slovníček nejdůležitějších pojmů. Kromě anglických výrazů je uveden i stručný popis všech výrazů – v žádném případě nejde o vyčerpávající definice, jde spíše o stručné vymezení významu, s jakým je daný pojem používán v oblasti modelování komplexních systémů. Slova uvedená kurzivou označují pojmy popsané v rámci slovníčku. S cílem přimět čtenáře, aby si prošel celý seznam, byly do slovníčku zařazeny i některé méně seriózní popisy.

Adaptace (adaptation) Přizpůsobení systému vlivům vnějšího prostředí.

Analytické řešení (analytical solution) Řešení rovnice nebo *modelu* pomocí exaktních matematických úvah. Lze použít pouze na řešení jednoduchých problémů a nejde příliš dobře automatizovat. Srovnej *numerické řešení*, *simulace*.

Analýza citlivosti (sensitivity analysis) Analýza chování *modelu*, při které se zaměřujeme především na vliv *parametrů* na chování modelu.

Autonomní agent (autonomous agent) Součást rozsáhlejšího *decentralizovaného systému*, která se samostatně rozhoduje na základě podnětů ze svého bezprostředního okolí. Používá se při *modelování pomocí agentů*.

Buněčný automat (cellular automaton) Diskrétní dynamický systém skládající se z pravidelné mřížky buněk, z nichž každá se chová jako konečně stavový automat. Změna stavu buňky závisí pouze na lokálních interakcích.

Decentralizovaný systém (decentralized system) *Systém*, který nemá žádné centralizované vedení ani centralizovaný zdroj informací, většinou se skládá z *autonomních agentů* a vykazuje znaky *samo-organizace*.

Dedukce (deduction) Z obecně platných principů vyvozujeme logickou úvahou platné závěry. Jde o logicky korektní a formálně uchopitelný styl uvažování, který však bohužel skoro nikdo nepoužívá. Srovnej *indukce*.

Diferenciální rovnice (differential equation) Rovnice popisující spojitou změnu určité proměnné. Nabušení matematici umí některé diferenciální rovnice řešit *analyticky*, většinová *populace* se spokojuje s *numerickým řešením*.

Ekologie (ecology) Vědecká disciplína zabývající se studiem vztahů organismů k *prostředí* a vztahů mezi organismy.

Emergentní chování (emergence) Chování na úrovni celku, které nemá žádný přímý vzor v chování či pravidlech jednotlivých částí. Viz též *samo-organizace*.

- Evoluce** (evolution) Biologická evoluce je změna dědičných vlastností *populace* v průběhu mnoha generací. Přeneseně se používá i v jiných oblastech s širším významem „vývoj“. Viz též *koevoluce*.
- Exponenciální růst** (exponential growth) Růst odpovídající exponenciální funkci; dochází k němu v situaci, kdy přírůstek stavu (např. populace, financí) je úměrný aktuálnímu stavu. V situacích s exponenciálním růstem lidé často dělají chyby v *intuitivním* myšlení.
- Fázový přechod** (phase transition) V původním významu jde o transformaci termodynamického systému při přechodu z jednoho stavu do druhého. Přeneseně se tento výraz používá pro situaci, kdy dochází k prudké změně v chování systému (modelu).
- Genetický algoritmus** (genetic algorithm) Metoda pro simulování základních principů biologické *evoluce* v počítači.
- Graf** (graph) Matematický objekt, který se skládá z uzlů a z hran spojujících uzly. Používá se k formálnímu zachycení vztahových vlastností.
- Holismus** (holism) Víra, že „celek je víc než součet částí“, tj. že pro porozumění *systému* jako celku nemůžeme studovat pouze části, ale že musíme klást důraz i na vztahy mezi nimi. Srovnej *redukcionismus*.
- Homeostáza** (homeostasis) Schopnost *systému* udržovat svoji vlastní *rovnováhu* pomocí regulačních mechanismů.
- Hra s nulovým součtem** (zero-sum game) Pojem z oblasti *teorie her* popisující situaci s dvěma aktéry, kdy zisk prvního je přesně vybalancován ztrátou druhého.
- Indukce** (induction) Způsob myšlení, který postupuje od konkrétního k obecnému, od pozorování konkrétních příkladů k zobecňování a usuzování o budoucím vývoji. Není logicky korektní, nicméně lidé ho velmi často a úspěšně používají. Srovnej *dedukce*.
- Intuice** (intuition) Poznání, k němuž dospíváme bezprostředně, bez logických úvah, přičemž proces, kterým jsme k němu došli, není patrný. V případě, že máme co do činění s *komplexními systémy*, bývá tento proces chybný.
- Logistický růst** (logistic growth, sigmoid growth) Růstová křivka tvaru „S“, vyjadřuje růst, který se blíží k určité limitě (kapacita prostředí).
- Koevoluce** (coevolution) Souběžná *evoluce* více entit (např. živočišných druhů nebo počítačových programů), které jsou svázány *zpětnou vazbou*. Označováno také jako „efekt červené královny“ (Red queen effect) podle příhody z knihy „Alenka v kraji za zrcadlem“.
- Komplexní systém** (complex system) *Systém* skládající se z velkého počtu částí, které mají mezi sebou velké množství vztahů a vzájemně se ovlivňují *složitým* způsobem.
- Komplexní síť** (complex network) Rozsáhlý *graf*, většinou odpovídající určité vztahové vlastnosti komplexního systému (např. vztahy mezi lidmi, spojení mezi servery), který je *složitý*.
- Korelace** (correlation) Vzájemná souvztažnost. Jev, kdy dva procesy vykazují vzájemně provázanou tendenci. Častou chybou *intuitivního* uvažování je zaměnění korelace za kauzalitu (causality), tj. vzájemnou závislost.

- Králík** (rabbit) Drobný savec, charakteristický dlouhýma ušima a silnými zadními běhy. Obývá širokou škálu prostředí, vyskytuje se v domácí i divoké variantě. Informatik si jej může snadno splést se zajícem, což je tvor, který žije v lese a má ještě delší uši než králík.
- Liška** (fox) Zvíře, které se v této knize žíví *králíky*. V realitě se žíví většinou něčím jiným.
- Mocninný zákon** (power-law) Distribuce prvků (událostí), ve které má několik málo prvků velkou frekvenci výskytu, zatímco většina prvků má malou frekvenci výskytu. Matematicky je popsána polyominální (mocninnou) funkcí. S podobným významem se používají např. pojmy Zipfův zákon, Paretův princip nebo pravidlo 80-20.
- Model** (model) Zjednodušená reprezentace reality, která některé aspekty vypouští a jiné zdůrazňuje, a tím nám pomáhá o realitě lépe uvažovat. Chování modelu zkoumáme například pomocí *analytického řešení* nebo *simulace*.
- Modelování** (modeling) Činnost, při které vytváříme modely. Anglický termín označuje také činnost provozovanou na módních přehlídkách, kterážto je finančně daleko výnosnější.
- Modelování založené na agentech** (agent based model, též individual-based modeling, agent-based systems, agent-based modeling and simulation) Přístup k modelování založený na *autonomních agentech* a lokálních interakcích, vhodný především pro modelování *decentralizovaných systémů*.
- Náhoda** (randomness) Proces bez jakékoliv pravidelnosti. Vhodná výmluva, když se vám něco nepovede.
- Negativní zpětná vazba** (negative feedback, counteracting feedback) *Zpětná vazba*, která vede k utlumení vstupních změn. Vede ke stabilizaci *systému*. Srovnej *pozitivní zpětná vazba*.
- Numerické řešení** (numerical solution) Přibližná metoda řešení (například soustavy *diferenciálních rovnic*) založená na velkém počtu dílčích aproximujících výpočtů. K výpočtům používáme *počítač*, protože jinak by nás to počítání brzy přestalo bavit. Srovnej *analytické řešení*.
- Oscilace** (oscillation) Chování, při kterém dochází ke kmitání okolo *rovnovážné* polohy (pravidelné zvyšování a snižování určité proměnné). Typické pro systémy dominované negativní *zpětnou vazbou* se zpožděním.
- Paradigma** (paradigm) Soubor názorů určujících naše chování, který považujeme za natolik zřejmý, že o tom ani neuvažujeme.
- Parametr** (parameter, convertor, system constant) Prvek *modelu*, který udává konkrétní číselnou hodnotu jevů v modelu popsaných. Parametry jsou většinou vnější prvky modelu, tj. prvky, které přímo nemodelujeme. Vliv parametrů zkoumáme v rámci *analýzy citlivosti*.
- Počítač** (computer) Stroj, který dělá to, co mu řeknete, a nikoliv to, co byste chtěli. Pokud se vám podaří přimět jej, aby vás poslouchal, pak je velmi užitečným pomocníkem pro provádění náročných *simulací* a *numerických výpočtů*.
- Populace** (population) Soubor jedinců stejného druhu žijících na určitém území v určitou dobu. Klíčový pojem v *ekologii*, přeneseně se používá například v *modelování pomocí agentů* a *genetických algoritmech*.

- Pozitivní zpětná vazba** (positive feedback, reinforcing feedback) *Zpětná vazba*, která vede k nárůstu vstupních změn. Může vést k destabilizaci systému, ale i k vytváření nových struktur. Srovnej *negativní zpětná vazba*.
- Produkční systém** (production system) Modelovací formalismus založený na podmíněných pravidlech s dynamicky se měnícími prioritami, vhodný pro zachycení *induktivního* uvažování.
- Prostředí** (environment) Vše, co se nachází mimo studovaný *system*.
- Racionalita** (rationality) Schopnost rozhodovat se objektivně a logicky korektně (s využitím *dedukce*) na základě všech dostupných informací. U člověka zatím nebyla pozorována. Srovnej *intuice, induktivní myšlení*.
- Redukcionismus** (reductionism) Víra, že *systemu* jako celku můžeme porozumět na základě detailního porozumění jednotlivým částem. Srovnej *holismus*.
- Rovnováha** (equilibrium) Stav, kdy v *systemu* nedochází ke změnám.
- Samo-organizace** (self-organization) Proces, při kterém se interní organizovanost *systemu* zvětšuje, aniž by docházelo k řízení z vnějšího zdroje nebo aby způsob organizace byl zakódován přímo v pravidlech. Dochází k ní v *decentralizovaných systémech*. Viz též *emergentní chování*.
- Simulace** (simulation) Experimentální zkoumání dynamického chování *modelu* v různých situacích. Srovnej *analytické řešení*.
- Složitost** (complexity) Pojem s příliš mnoha významy, než aby se dal popsat jednou větou. V této knize používán většinou ve významu „ani pravidelný, ani náhodný, ale něco mezi“.
- Stavový prostor** (state space, phase space) Popis všech možných chování *systemu*, respektive jeho *modelu*. Pokud je například model popsán n proměnnými, stavy *modelu* jsou body v n -rozměrném prostoru a stavový prostor je tvořen těmito stavy a přechody mezi nimi.
- System** (system) Něco, co má smysl studovat jako celek. System by mělo být možno ohraničit proti zbytku světa, na který se díváme jako na *prostředí*.
- Systemová dynamika** (system dynamics, system modeling, compartmental modeling) Přístup k modelování *komplexních systémů* založený na pohledu shora, na explicitním popisu *zpětných vazeb*. Modely představují (graficky vyjádřené) *diferenciální rovnice*, simulace spočívá v jejich numerickém řešení.
- Teorie her** (game theory) Oblast aplikované matematiky, která se zabývá modelováním *racionálního* chování při strategickém rozhodování.
- Tok** (process, flow) Prvek *modelu* v *systemové dynamice*, který udává změnu velikosti *zásobárny*, tj. rychlost změn v *systemu*.
- Umělá neuronová síť** (neural network) Matematický model imitující fungování skutečných neuronových sítí. Model je založen na orientovaném váženém *grafu*.
- Zpětná vazba** (feedback) Proces, při kterém je část výstupu *systemu* současně vstupem pro další činnost tohoto *systemu*. Alternativně se můžeme na zpětnou vazbu dívat jako na cyklus příčin a následků bez jasných vstupů a výstupů, ve kterém příčiny v jedné části *systemu* způsobují následky, které, na oplátku, způsobují změny v původních příčinách. Rozlišuje *pozitivní zpětnou vazbu* a *negativní zpětnou vazbu*.
- Zásobárna** (reservoir, stock) Pojem, kterým se v *systemové dynamice* označuje proměnná zachycující stav *systemu*.

B Přehled modelů

Pro nejdůležitější modely zmíněné v knize zde uvádíme shrnutí základních bodů: účel modelu, použitý formalismus a základní popis modelu. Pro každý model je uveden odkaz na část, ve které je model popsán; k většině modelů je možné na internetu dohledat doplňující materiály a často i interaktivní prezentace. Protože však jsou dostupné materiály vesměs v angličtině, uvádíme také anglické názvy modelů (pokud se český a anglický název liší).

Dilema vězně (Prisoner's dilemma) Model, ve kterém se dva hráči rozhodují mezi spoluprací a soutěžením. Základní model vychází z teorie her. Model můžeme analyzovat různými způsoby (matematická dedukce, turnaje počítačových strategií) a dále rozšiřovat (náhoda, prostor, komplexní sítě, více hráčů). Jde o jednoduchý model, který má však mnoho aplikací, využívá se především při studiu spolupráce (šíření, udržitelnost, podpora). Viz 14.1, 14.2, 14.3.

El Faron bar Modelová situace, ve které se lidé rozhodují na základě předchozích zkušeností, zda navštíví bar, či zůstanou doma. Model je postaven na klasifikačních systémech. Model ilustruje, jak lze modelovat induktivní myšlení. Viz 8.2.

EpiSimS Rozsáhlý systém pro modelování epidemií, který umožňuje zahrnutí reálných geografických a demografických dat. Model slouží k předpovídání rozšíření hrozících epidemií a k testování technik zásahu proti epidemiím. Viz 11.4.

Hra Život (Game Life) Buněčný automat s velmi jednoduchými pravidly rozlišující pouze dva stavy buněk (živá, mrtvá). I přes svou jednoduchost model vykazuje velmi zajímavé a komplikované chování. Název je odvozen schopností modelu generovat životu podobné struktury z náhodného počátečního stavu. Viz 12.1.

Jestřáb a holubice (Dove and hawk) Model teorie her zachycující soupeření o potravu. Ilustruje, že neexistuje nějaká absolutní evoluční „zdatnost“, ale že úspěšnost tvora (strategie) závisí na složení populace (viz též pojem evolučně stabilní strategie). Model lze zpracovat analyticky, systémovým modelováním i pomocí agentů a lze jej dále rozšiřovat. Viz 12.2.

Kultura Anasazi (Artificial Anasazi) Model s agenty zachycující dynamiku konkrétní populace (kultura Anasazi žijící v USA na počátku 2. tisíciletí). Cílem modelu je co nejvěrněji reprodukovat historická data a pokusit se odpovědět na otázku, zda vyhynutí kultury mohlo být způsobeno pouze měnícími se environmentálními podmínkami. Viz 13.3.

- Langtonův cyklus** (Langton cycle) Jednoduchý abstraktní model sebe-reprodukce řízené strukturou. Jde o buněčný automat, počáteční stav obsahuje jednu kopii cyklu, který se následně během simulace kopíruje a množí. Viz 12.1.
- Lovec a kořist** (Predator-prey) Model interakce dvou živočišných druhů, kdy jeden se živí výhradně druhým. Nejjednodušeji lze modelovat pomocí matematického modelování (nejznámější varianta je takzvaný Lotka-Voltera model) nebo pomocí agentů. Vhodný zejména pro pedagogické účely, ve složitějších verzích pak pro získání vhledu do fungování ekosystémů. Viz 6.2, 7.4, 10.1.
- Modely hejna, hlenky, mravenců** (Boids, slime mold, ants models) Jednoduché abstraktní modely s agenty, které ilustrují samo-organizované chování decentralizovaných přírodních systémů. Viz 12.3.
- Normy a meta-normy** (Norms game, Meta-norms game) Rozšíření modelu *Dilema vězně*, které zahrnuje více hráčů a možnost přímého trestání. Model se analyzuje pomocí upraveného genetického algoritmu. Účel modelu je zkoumání způsobu, jakým se ustanovuje norma ve společnosti. Viz 14.3.
- Pólyova urna** (Pólya urn, Pólya process) V základní verzi čistě abstraktní model, při kterém taháme černé a bílé kuličky s urny a pravděpodobnost vytažení černé kuličky závisí na dříve vytažených kuličkách. Jde o elegantní příklad systému dominovaného pozitivní zpětnou vazbou. Model se dá aplikovat na mnoho ekonomických situací. Viz 13.1.
- Segregace** (Segregation) Abstraktní model s agenty – město tvaru mřížky, ve kterém žijí dva druhy obyvatel, přičemž každý chce bydlet v okolí, kde je alespoň část obyvatel stejná jako on. Model ilustruje, jak se chování na úrovni celku (vysoká míra segregace) může lišit od pravidel na úrovni jednotlivce (vysoká míra tolerance). Viz 7.4.
- SIS, SIR, SIRS modely** Jednoduché abstraktní modely epidemií, které lze realizovat různými způsoby (matematické modely, systémové modely, modely pomocí agentů). Ve své základní podobě slouží k ilustraci základních principů šíření epidemií. Slouží také jako základ pro složitější a realističtější modely epidemií (viz *EpiSimS*). Viz 11.1, 11.2.
- Svět sedmikrásek** (Daisyworld) Imaginární svět, na kterém rostou pouze černé a bílé sedmikrásky, které mění albedo planety a tím ovlivňují podmínky pro svůj vlastní růst. Můžeme modelovat pomocí systémové dynamiky nebo pomocí pravděpodobnostního buněčného automatu. Model ilustruje princip homeostázy, původně byl navržen na podporu hypotézy Gaia. Viz 12.4.
- Tierra** Model evoluce digitálních organismů, které soupeří o prostředky virtuálního počítače. Model představuje pokus o zachycení otevřené evoluce. Viz 12.2.
- Umělý trh** (Artificial market) Model jednoduchého trhu, který ilustruje rozdíly mezi ideálním trhem s racionálními agenty a trhem s omezeně racionálními agenty učícími se ze zkušeností (induktivně). Model je realizován pomocí klasifikačního systému. Viz 13.2.
- World3** Rozsáhlý systémový model, jehož cílem je studium interakce expandující lidské ekonomiky a limitů planety. Model obsahuje reálná data, je však vysoce agregovaný. Neslouží tedy ke konkrétním předpovědím, ale pouze ke studiu hlavních trendů. Viz 15.

C Softwarové nástroje

Hlavní text knihy popisuje základní principy jednotlivých typů modelování a nezmiňuje se příliš o konkrétních způsobech realizace modelů. K této realizaci můžeme využít celou škálu softwarových nástrojů. Informace o softwarových nástrojích však rychle zastarává – objevují se stále nové prostředky a nové verze s novými možnostmi. Proto zmiňujeme přehled nástrojů pouze zde v příloze a jen velmi stručně. Přehled je určen k tomu, aby se čtenáři zvládli rychle zorientovat v základních možnostech, jež mají k dispozici, a aby byli schopni si dohledat nástroj, který je nejvhodnější pro jejich potřeby.

Další informace o jednotlivých nástrojích lze dohledat na internetu – odkazy neuvádíme, protože to je obzvláště rychle zastarávající informace, a navíc mají nástroje natolik specifické názvy, že jejich webové stránky lze snadno najít internetovým vyhledávačem. Nejdůležitější odkazy jsou navíc uvedeny na webové stránce knihy na www.radekpelanek.cz.

Pokud není explicitně uvedeno jinak, jsou níže uvedené nástroje volně dostupné.

Programovací jazyky

Nejobecnější způsob, jak realizovat modely, je použít obecný programovací jazyk a implementovat celý model „na zelené louce“. Tento přístup nám neklade žádná umělá omezení a celý návrh modelu může přizpůsobit potřebám konkrétní studie. Cenou, kterou za tuto volnost platíme, je nutnost implementovat a ladit vše samostatně, často i věci, které byly už mnohokrát provedeny („vynalézání kola“). Samotná volnost navíc u modelování není vždy výhodou.

Použití obecného programovacího jazyka pro modelování je tedy smysluplné, pouze pokud modelář už jazyk velmi dobře ovládá a je pro něj jednodušší udělat práci navíc než se učit něco nového. Pokud tento přístup někdy využijeme, pak především při návrhu modelů s agenty. V tomto případě využíváme objektově orientovaný jazyk, nejčastěji se používá **Java** či **C++** za použití dostupných specializovaných knihoven pro ABM modelování (viz níže). Specializované knihovny existují například i pro neuronové sítě a genetické algoritmy.

Obecné programovací jazyky však můžeme využít nejen pro vytváření vlastního modelu, ale i pro další činnosti související s modelováním, například pro vytváření jednoduchých prototypů modelů, na kterých si zkusíme základní principy, nebo pro

automatizaci spouštění experimentů a zpracování dat. Pro tyto účely se hodí především skriptovací jazyky (např. **Python**, **Perl**).

Modelování s agenty

Pro modelování s agenty existují prostředí s vlastním modelovacím jazykem a dále knihovny postavené na obecných programovacích jazycích. Typickým příkladem prostředí, které používá jednoduchý skriptovací jazyk, je **NetLogo**, pomocí něhož byly realizovány mnohé modely popsané v této knize. Výhodou použití takového prostředí je jednoduchost a snadnost použití, které umožňuje rychle vyrobit poměrně efektní modely. NetLogo obsahuje také předpřipravenou rozsáhlou sbírku příkladů, kterou lze použít pro inspiraci při vytváření vlastních modelů, a manuál je dostupný i v češtině. Nevýhodou je nutnost učit se speciální skriptovací jazyk a omezené modelovací možnosti (například omezení na dvourozměrný svět). Pro velké modely pak je také simulace výrazně pomalejší než při optimalizované implementaci. Nástroje tohoto typu jsou tedy vhodné především pro menší modely, výuku a zkoušení základních konceptů.

Pro rozsáhlé modely můžeme využít specializované knihovny postavené na obecných programovacích jazycích (většinou na Javě). Tato prostředí poskytují knihovny implementující typické potřeby při realizaci ABM modelů a umožňují nám tak soustředit se na specifika konkrétního modelu. Jde například o prostředí **RePast**, **Swarm**, **Ascape** a **AnyLogic** (AnyLogic je komerční, podporuje však i systémovou dynamiku). Výhodou použití těchto knihoven je vysoká modelovací síla a zároveň možnost využít předpřipravené nástroje. Nevýhodou jsou vysoké počáteční „investice“ – nutnost naučit se používat komplikovaný prostředek.

Nástroje pro systémové modelování

Nástrojů pro systémové modelování existuje více, všechny však mají podobnou funkcionalitu: mají grafický editor pro vytváření modelů, automaticky generují diferenciální rovnice, umožňují numerickou simulaci rovnic (pomocí několika metod) a zobrazení dat (grafů funkcí) a obsahují podporu pro provádění analýz modelu (např. analýza citlivosti).

Konkrétní příklady nástrojů jsou **Stella**, **VenSim** a **PowerSim**. Všechny uvedené nástroje jsou komerční, avšak většinou mají volně dostupnou demo-verzi, která má jen mírná omezení.

Analýza komplexních sítí

Pro jednoduchou vizualizaci malých grafů je nejvhodnější program **dot** (z balíku **GraphViz**), který je volně dostupný a jednoduše použitelný. Pro rozsáhlejší nebo sofistikovanější vizualizace grafů je možné použít složitější komerční nástroje, jako je například **AiSee**. Dále existují programy umožňující kromě vizualizace i analýzy

grafů (například výpočet různých koeficientů grafu, operace nad grafy). Z volně dostupných nástrojů je nejvíce propracovaný **Pajek**.

Matematický software

Matematické balíky jsou vhodné především pro matematické modelování a pro inženýrské aplikace modelování, často však obsahují například i podporu pro buněčné automaty, genetické algoritmy nebo neuronové sítě, a jsou tak využitelné pro celou škálu různých modelů. Mezi nejznámější nástroje např. **Matlab** (s rozšířením **Simulink**), **Maple** a **Matematica**. Uvedené balíky jsou komerční a dosti drahé. Volně dostupné alternativy mají většinou výrazně slabší funkcionalitu, mezi nejpropracovanější patří nástroj **Octave**, jehož prostředí je do velké míry kompatibilní s nástrojem Matlab.

Zpracování dat

Kromě programů pro vlastní modelování potřebujeme ještě nástroje pro zpracování výsledků simulací. Modelovací balíky sice často obsahují částečnou podporu pro zpracování dat a vizualizaci výsledků, ale při tvorbě rozsáhlejších studií je lepší provádět zpracování dat samostatně ve specializovaném nástroji.

Na základní analýzy postačí dobré zvládnutí tabulkového kalkulátoru (např. komerční **Microsoft Excel** nebo volně dostupná alternativa **OpenOffice Calc**). Na složitější analýzy využijeme statistické programy (např. komerční **Statistica** nebo volně dostupný **R Project**). Pro vykreslování grafů je dobrým nástrojem **gnuplot**, jehož textové rozhraní je sice náročnější na počáteční naučení než u „klikacích“ nástrojů, tato investice se nám však rychle vrátí, především pokud zpracováváme velké množství dat.

D Náměty na cvičení a projekty

Tato příloha poskytuje několik námětů pro praktické procvičení modelování. Nejprve uvádíme docela podrobný rozpis námětů k tématům epidemie a populační dynamika, což jsou témata, která se opakovaně vyskytovala v hlavním textu knihy a jež jsou obzvláště vhodná pro úvodní seznámení s modelováním. K oběma tématům jsou uvedeny úkoly se základními modely (především analýzy citlivosti) a několik námětů na rozšíření základních modelů. Dále následují obecné náměty na projekty, u kterých důležitou část tvoří dohledání dalších informací a domyšlení konkrétní podoby modelu.

Ve webové příloze na stránkách www.radekpelanek.cz jsou uvedeny ukázkové modely epidemií a populační dynamiky (vypracované v nástrojích NetLogo a Stella). Na webu jsou také odkazy na další materiály vhodné pro úvodní cvičení s modelováním.

D.1 Epidemie

Téma modelování epidemií je probráno v kapitole 11, kde jsou detailně popsány základní modely. Zde tedy nebudeme opakovat popis těchto modelů, ale dáme konkrétní tipy ke cvičení s těmito základními modely a náměty na rozšiřující projekty.

Analýzy základního modelu

Jako výchozí bod je u modelování epidemií vhodné zvolit model SIR (Susceptible – Ill – Removed, tj. zdravý – nemocný – mrtvý). Základní systémový model i model s agenty jsou popsány v části 11.2. Jako první krok cvičení je vhodné vytvořit vlastní verzi těchto modelů. Chování zhotoveného modelu by mělo replikovat chování zobrazené na obr. 11.2.

Model SIR má dva základní parametry: infekčnost a úmrtnost. S vytvořenými modely proveďte základní analýzy citlivosti, tj. zjistěte, jak tyto parametry ovlivňují chování modelu. Konkrétní otázky:

- Jak závisí počet mrtvých na hodnotách parametrů? Znamená větší úmrtnost více mrtvých? Pokud máte model správně, pak by neměla. Jak to?
- Po jakém čase dochází k stabilizaci stavu? V jakém čase epidemie kulminuje (největší počet nakažených)? Jak tyto časy závisí na hodnotách parametrů?

Rozšíření

Pokud dobře porozumíte základnímu modelu, můžete jej zkusit rozšířit. Raději vždy zkoumáme jen jedno rozšíření, protože vyhotovení modelu, který by zahrnoval více rozšíření, je docela náročné. Přesněji řečeno není až tak složité sestavit *nějaký* rozšířený model, ale je náročné vyladit komplikovaný model tak, aby se choval rozumně a byl smysluplný. Příkladem relativně dobrého rozšíření základního modelu je model AIDS zahrnutý ve standardní sbírce NetLoga (Wilensky, 1998).

Pro všechna rozšíření je dobré opět provést analýzy citlivosti. Jak se u rozšířeného modelu změnila odpověď na výše uvedené otázky? Jak ovlivňují nově přidávané parametry chování modelu?

Dynamika nemoci Můžeme použít další dvě základní varianty popsané v kapitole 11: SIS (Susceptible – Ill – Susceptible) a SIRS (Susceptible – Ill – Recovered – Susceptible). Tyto varianty vyžadují jen malou úpravu modelu. Dále můžeme v modelu zpracovat časová hlediska, například zakomponovat inkubační dobu, dobu nemoci nebo proměnlivou infekčnost (například oscilace simulující závislost na ročním období). Tato rozšíření lze relativně jednoduše zakomponovat do modelu s agenty. V systémovém modelu jsou realizovatelná také, ale pomocí prostředků, které jdou nad rámec toho, co bylo probíráno v této knize.

Subpopulace Populaci rozdělíme na několik částí, v rámci kterých je intenzivní kontakt mezi členy populace, kdežto mezi jednotlivými částmi je jen omezený kontakt, tj. modelujeme například průběh epidemie na ostrovech. Model s agenty lze upravit jednoduše – můžeme například dvourozměrnou mřížku rozdělit zdí na několik místností a mezi nimi nechat jen malé dveře, případně vytvořit zcela oddělené místnosti, mezi kterými se agenti s malou pravděpodobností „teleportují“ (simulace přeletu mezi ostrovy). V systémovém modelu je úprava v principu také jednoduchá (rozdělíme každou zásobárnu na několik podzásobáren), bez použití pokročilejších technik je však úprava pracná.

Epidemie na síti Toto rozšíření bylo také popsáno a ilustrováno v kapitole 11. Místo náhodného pohybu jsou teď agenti spojeni vazbami, po kterých se epidemie může šířit. Nástroj NetLogo obsahuje ukázkové modely pro vytvoření sítí různého typu (náhodná, bezškálovitá, malý svět). Tyto modely můžeme vcelku přímočaře zkombinovat se základním modelem epidemie. Při analýzách se můžeme zaměřit na to, jak topologie sítě ovlivňuje průběh epidemie.

Zásahy proti epidemii Můžeme zkusit do modelu začlenit například následující zásahy: plošná vakcinace, cílená vakcinace, karanténa nemocných, eliminace nemocných, preventivní eliminace potenciálně nakažených. Který zásah je nejvíce efektivní? Jaký je vztah mezi rozsahem zásahu (a potažmo tedy jeho cenou) a jeho efektivností (snížení počtu nemocných)? Kdy dochází k nejlepšímu poměru „cena/výkon“?

Variace tématu

Následující témata, i když na první pohled zní úplně jinak než epidemie nemocí, lze modelovat velmi podobně jako epidemie. Pokuste se interpretovat model SIR v kontextu příslušné oblasti a případně jej upravit a rozšířit pro danou oblast.

Formace názorů Názory lidí jsou do velké míry ovlivněny názory lidí v jejich okolí. Vytvořte model formování názorů, ve kterém je počet možných názorů omezen na malé množství (např. preferovaná politická strana) a ve kterém je zohledněn vliv okolí. Uvažte různou strukturu kontaktů mezi lidmi, tj. různé možnosti volby okolí, ze kterého je člověk ovlivněn (např. pravidelná mřížka, náhodný graf, malý svět, bezškálovitá síť). Analyzujte vliv struktury kontaktů na chování modelu. Můžete také uvážit různé typy lidí (tvrdohlavec, dobrý řečník) a jejich vliv na chování modelu.

Adaptace nových technologií Lidé mají k novým technologiím různé postoje: někteří se nadšeně vrhají do všeho nového, většina si počká, až se nová věc osvědčí, a pak teprve si ji pořídí, a někteří tvrdohlavě zůstávají u starých osvědčených technologií, jak dlouho to jen jde (více informací lze najít v knize „Diffusion of Innovations“ od E. M. Rogerse, resp. postačí i shrnutí hlavních myšlenek, která jsou dostupná na webu). Vytvořte model ilustrující šíření nových technologií ve společnosti, který v sobě bude obsahovat uvedené kategorie lidí. Dále můžete zkoumat vliv reklamy a jejího zacílení (plošná reklama versus cílená reklama na určitou skupinu).

Šíření módy a kultury Vytvořte model zachycující šíření módního či kulturního trendu a vzájemného ovlivňování takových trendů. Do modelu zkuste zapracovat následující princip: čím si jsou dva lidé podobnější, tím větší šance, že se vzájemně ovlivní. Pokud Tomáš i Marek poslouchají metal a nosí džíny, je velká šance, že Marek ovlivní Tomášovu volbu časopisu, kdežto Jan, který chodí v obleku na operu, se Markem příliš ovlivnit nenechá. Pro konkrétní inspiraci se můžete podívat na článek „The dissemination of culture: A model with local convergence and global polarization“ (Axelrod, 1997a).

D.2 Populační dynamika

Oblast populační dynamiky je také věčné téma pro výuku a ilustraci základních konceptů, protože v této oblasti i velmi jednoduché modely mají relativně realistické a snadno interpretovatelné chování. Modelování se však používá nejen pro výuku, ale i při praktických aplikacích (např. management chráněných území). Zde uvedeme náměty na konkrétní cvičení se základním modelem lovec-kořist a potom několik rozšiřujících námětů, které ilustrují směr, jímž se ubírají realističtější modely.

Základní modely

Modely z oblasti populační dynamiky jsme používali opakovaně v 2. části knihy. Základní modely populační dynamiky jsou vhodné pro úvodní cvičení na ovládnutí

základů modelovacího nástroje. Konkrétně se pro začátek hodí modely reprodukcující základní vzory chování systémů (viz obr. 6.4 na str. 69):

- exponenciální růst – šíření jedné populace bez omezení,
- logistický růst – šíření jedné populace s omezenou kapacitou prostředí,
- oscilace – lovec a kořist, resp. konzument s obnovujícím se zdrojem,
- přestřel a kolaps – konzument s neobnovujícím se zdrojem.

Tyto modely jsou vcelku snadno realizovatelné jak pomocí systémového modelování, tak pomocí modelování s agenty. V obou případech je dobré začít tím, že uděláme co nejjednodušší model, který replikuje příslušný vzor chování. Nápovědy k řešení lze nalézt v 2. části knihy, kde je několik modelů tohoto typu probíráno.

Na základních modelech můžeme vyzkoušet analýzy citlivosti. Z uvedených základních modelů je pro analýzy nejhodnější model lovec a kořist (oscilující chování), jehož analýza je ostatně rozebrána detailně v kapitole 10. Zde tedy jen stručně shrňme možné úkoly:

- Najděte rovnovážný stav pro systémový model. Při jakých počátečních hodnotách je systém v rovnováze? Řešení zkuste odvodit pokud možno analyticky, nikoliv metodou pokus-omyl.
- Vykreslete chování modelu nejen pomocí časové osy, ale i pomocí stavového diagramu. Ve stavovém diagramu určete rovnovážný stav.
- Proveďte analýzu citlivosti. Jak ovlivňují parametry modelu velikost a frekvenci oscilací? Při jakých hodnotách parametrů dochází k vymření populace?
- Vyzkoušejte různé zásahy do systému (např. externí vylovení části kořisti), a to jak jednorázové, tak pravidelné. Jakým způsobem se mění chování systému?

Variace tématu

Následující témata lze většinou modelovat pomocí stejných principů jako základní modely.

Populační dynamika dvou konkurentů Vytvořte model populační dynamiky dvou druhů, které si nepřímou konkurují, tj. nedochází mezi nimi k predaci, pouze se živí například stejným zdrojem. Pomocí modelu ilustруйте různé scénáře, ke kterým může dojít (vyhynutí jednoho druhu, ustanovení stabilní rovnováhy). Přidejte do modelu společného predátora a pomocí modelu zkuste ilustrovat, jak za této situace může vyhynutí predátora vést k poklesu stavu (jednoho druhu) kořisti.

K-stratégové a r-stratégové Zjednodušeně řečeno K-stratégové mají málo potomků, investují do nich hodně energie, žijí dlouho a daří se jim ve stabilním prostředí, kdežto r-stratégové mají hodně potomků, investují do nich málo energie, žijí krátce a daří se jim v proměnném prostředí. Najděte si více informací o těchto pojmech a vytvořte model, který bude ilustrovat K-strategii, r-strategii a rozdíly mezi nimi.

Biodiverzita ostrovů Zjednodušeně řečeno biodiverzita území je počet druhů žijících na tomto území. Biodiverzita ostrovů závisí zejména na následujících parametrech: klimatické podmínky na ostrově, diverzita prostředí, velikost ostrova a vzdálenost ostrova od pevniny. Navrhněte model s využitím agentů (agenti představují zvířata

či rostliny různých druhů), který názorně ilustruje závislost diverzity na uvedených parametrech (nemusí být zohledněny všechny parametry).

Tragédie obecní pastviny Tragédie obecní pastviny (Hardin, 1986) je modelová situace, kdy na společné pastvině pase ovce řada farmářů. Pokud dojde k překročení limitu pastviny (příliš mnoho ovcí), dojde ke kolapsu (pastvina se nestihá obnovovat). Protože však pastvina nikomu nepatří (je obecní) a každý farmář se snaží mít co nejvíce oveček, dojde ke kolapsu, přestože je to pro všechny zúčastněné nevýhodné. Tento modelový scénář se vztahuje na mnoho reálných situací, např. rybolov nebo znečištění atmosféry. Vytvořte model této situace. Pokuste se navrhnout různá opatření (např. zákazy, kvóty, daně), která mohou pomoci situaci zlepšit. Opatření začleňte do modelu a vyhodnoťte pomocí simulace. K tomuto tématu lze najít mnoho podkladů v literatuře i na internetu (anglický termín pro vyhledávání: „tragedy of the commons“).

Trvale udržitelný rybolov Konkrétním případem konceptu tragédie obecní pastviny je rybolov. Vytvořte dvourozměrný model rybolovu a analyzujte na tomto modelu vliv různých strategií rybolovu (omezení na počty lodí, zakázané oblasti rybolovu, kvóty na úlovek). Při analýze se zaměřte na dlouhodobou udržitelnost a na srovnání dlouhodobých a krátkodobých zisků.

Sukcese Sukcese je vývoj společenstva, spočívající v postupném a jednosměrném nahrazování populací určitých druhů populacemi jiných druhů. Příkladem sukcese je například zarůstání pole, které zůstane ležet ladem. Nejdříve na něm začnou růst jednoleté byliny, později keře, pak pionýrské druhy stromů a po mnoha letech bude na místě původního pole les. Podrobnější informace lze nalézt v každé základní učebnici ekologie (případně na internetu). Vytvořte abstraktní model ilustrující základní průběh sukcese.

Jestřáb a holubice Realizujte model Jestřáb a holubice, který je stručně popsán v kapitole 12. Pro zpracování modelu použijte matematický model (rovnice vyjadřující vztahy mezi celkovými počty jestřábů a holubic) i model s agenty (každý agent má svoji strategii, pohybují se náhodně po ploše, při setkání se utkají, množí se dle bodových zisků). Srovnajte výsledky obou modelů. Přidejte dále do modelů rozšířené strategie (např. odvetník, mixovaná strategie). Určete pro jednotlivé varianty evolučně stabilní strategii a pomocí simulace zkoumejte, jakým způsobem a jak rychle systém k evolučně stabilní strategii směřuje.

D.3 Obecné náměty

Zde uvádíme obecné a široce pojaté náměty na projekty. Náměty je nutno upřesnit, vybrat z nich konkrétní problém, formulovat jasně účel modelu – tato činnost je součástí projektu. Většina námětů je zpracovatelná s pomocí nástrojů NetLogo nebo Stella, v některých případech je vhodnější použít obecný programovací jazyk. Některé náměty jsou vhodné pouze pro určitý modelovací přístup (např. k modelování davu je rozhodně vhodné použít agenty), u jiných námětů naopak přicházejí do úvahy různé

modelovací přístupy a může být zajímavé udělat v rámci projektu dva diametrálně odlišné modely a vzájemně je porovnat.

Sociologie

Vznik měst Navrhněte model ilustrující proces vzniku měst. Vznik měst ovlivňuje mnoho faktorů, nicméně pro účel modelu se omezte pouze na jeden z nich, např. vliv krajiny, vztah mezi vznikem měst a cest nebo souvislosti mezi obchodem a vznikem měst.

Modelování davu Vytvořte model ilustrující chování davu lidí v prostorech s úzkými průchody (např. přestupní stanice metra, fotbalový stadion, evakuace z hořícího domu). Pokuste se vytvořit co nejjednodušší pravidla chování jednotlivců, která povedou k co nejméně nevhodnému chování na úrovni davu. Pro zvolená pravidla vyzkoušejte několik podobných způsobů uspořádání prostoru (např. umístění průchodů, šířka chodeb) a analyzujte vliv uspořádání prostoru na chování davu (např. čas, za který se prostor vyprázdní).

Drogy Vytvořte model ilustrující šíření užívání drog ve společnosti. Zaměřte se například na efektivitu různých opatření proti šíření drog (např. plošná preventivní osvětová kampaň, plošná odvykávací kampaň, cílené zatýkání dealerů, asistence závislým) nebo na vliv společenského uspořádání na rozšíření drog (relativně homogenní společnost versus výrazně sociálně diferencovaná společnost).

Média Mezi médii a společnostmi existují složité zpětné vazby. Média sice názory společnosti do jisté míry formují, současně jsou však názory společnosti ve velké míře ovlivňována (alespoň v demokratické, kapitalistické společnosti). Důsledky jsou neintuitivní: pluralita médií nevede k pluralitě prezentovaných informací, jak je vidět například na desítkách amerických zpravodajských stanic, které všechny prezentují téměř tytéž informace. Pokuste se zpětné vazby mezi médii a společnostmi ilustrovat na modelu.

Biologie

Stádo Vytvořte model pasoucího se stáda. Stádo by se mělo držet pohromadě a současně by se mělo postupně přesouvat na méně vypasenou plochu. Možná rozšíření: složitější terén (neúrodná půda, svah), reakce stáda na útok dravce (vlk), hlídací pes.

Sociální hmyz Sociální hmyz (např. mravenci, včely) je typickým příkladem decentralizovaného samo-organizujícího se systému. Najděte v literatuře popis konkrétního chování vybraného druhu (např. sběr potravy, stavba hnízda, rojení) a vytvořte zjednodušený model tohoto chování.

Evoluce pohybu Definujte jednoduchý abstraktní model pohybového aparátu, např. plavání či pohyb po rovné podložce, kde tělo je série kloubů pospojovaná pevnými

spojnicemi. Dále definujte pravidla popisující pohyb a pomocí genetického algoritmu se pokuste z náhodných pravidel vyvinout pravidla schopná co nejrychlejšího pohybu.

Koevoluce, mimikry, symbióza Inspirujte se konkrétními příklady koevoluce, mimikrů či symbiózy v přírodě a vytvořte abstraktní model, který bude ilustrovat některý z těchto jevů – cílem by neměla být co největší realističnost vzhledem k určitému příkladu, ale dobré ilustrování základních principů, na kterých tyto jevy fungují.

Model růstu Celý organismus vzniká z jedné buňky, buňky vznikají lokálním dělením, všechny nesou stejnou genetickou informaci – a přesto vzniká mnohobuněčný organismus, ve kterém jsou buňky značně rozlišeny a mají svou speciální funkci. K tomu dochází díky mezibuněčným signálům a působení prostředí. Najděte si více podkladových informací, nejlépe konkrétní informace k růstu u jednoduchého organismu. Vytvořte abstraktní model růstu, který bude ilustrovat hlavní principy.

Ekologie

Horní hranice lesa Navrhněte model ilustrující následující jev: „Přestože klima se mění s nadmořskou výškou zcela plynule, horní hranice lesa bývá v horách často nápadně ostrá. Je to tím, že les sám vytváří celkově stabilnější mikroklima, což zpětně podporuje zmlazování stromků, a stín porostu zároveň znemožňuje existenci světlo-milných druhů horských holí. Naopak drsné klima holí znemožňuje růst stromů a tím udržuje druhy světlo-milné. V rámci každého prostředí tedy existuje zpětná vazba mezi klimatem a vegetací, kdy klima podporuje určitou vegetaci a vegetace ovlivňuje mikroklima.“ (Storch, Mihulka, 2000).

Voda a stromy Vytvořte model ilustrující vliv stromů na koloběh vody. Základní princip je jednoduchý: stromy vodu zadržují, a tak zpomalují koloběh vody. Můžeme však zkoumat různé variace na toto téma: jednoduchý systémový model, dvourozměrný model znázorňující krajinu (každé pole má svou nadmořskou výšku), začlenění efektu eroze, vliv stromu na mikroklima (vypařování vody, formace mraků).

Požáry V amerických národních parcích se jistou dobu systematicky snažili hasit všechny požáry (s dobrým úmyslem pomoci přírodě). Tato politika měla za následek kumulaci velkého množství suchého dřeva a následně obrovské požáry, které byly neuhasitelné. Vytvořte zjednodušený model této situace a pomocí modelu proveďte analýzu různých přístupů k hašení požárů (např. nehasit žádné, hasit vše, hasit, pouze pokud překročí určitou mez).

Další oblasti

Obchody Zamyslete se nad tím, jak jsou ve městě rozloženy obchody (např. podobné obchody často bývají u sebe, na kraji města je řada velkých hypermarketů). Pokuste se identifikovat faktory, které ovlivňují polohu obchodů. Najděte zpětné vazby. Navrhněte model ilustrující nejdůležitější faktory a zpětné vazby. Zamyslete se nad tím,

jak moc je současné rozmístění obchodů výhodné z pohledu společnosti jako celku a zkuste navrhnout (a na modelu ilustrovat) opatření, která by mohla vést k vyšší efektivitě z pohledu společnosti (např. omezení nebo naopak uvolnění regulace).

Cena ropy Ropa je klíčovou surovinou současné civilizace, a cena ropy je tedy jedním z indikátorů stavu velmi komplexního systému. Vytvořit realistický model pro cenu ropy by bylo velmi náročné, pro účel projektu si tedy vyberte jeden z aspektů ovlivňujících cenu ropy a ten namodelujte. Může jít například o vliv katastrof (přírodních pohrom, válek) na cenu v krátkodobém horizontu, vliv organizace OPEC a jejích regulačních opatření ve střednědobém horizontu, o obousměrný vztah ekonomického růstu a ceny ropy nebo o vliv neobnovitelnosti, a tedy konečnosti zdroje na vývoj ceny v dlouhodobém horizontu.

Hypotéky Vytvořte model inspirovaný americkou krizí trhu s hypotékami (aktuální především v letech 2007–08). Tato krize byla způsobena propletenými zpětnými vazbami mezi rizikovými hypotékami, rostoucí úrokovou mírou, neschopností klientů splácet a klesající cenou nemovitostí vlivem přebytku nabídky.

Mikrosimulace dopravy Vytvořte model simulující konkrétní dopravní situaci (série křižovatek, kruhový objezd, mimoúrovňová křižovatka). Pomocí simulace porovnejte různé možnosti realizace křižovatky a vyhodnoťte, která je nejvýhodnější. Pokuste se najít a na modelu ilustrovat situaci, kdy neintuitivní opatření vede ke zlepšení dopravní situace (např. omezení rychlosti vedoucí ke zvýšení celkové efektivity).

Bitva Vytvořte model bitvy dvou armád. Do modelu začleňte některé z následujících prvků: efektivnost zbraní, využití terénu (např. bránění hradu), využití různých typů jednotek, shlukování a vytváření formací, vývoj morálky a dezerce podle situace.

Robot – sběr plechovek Robot se pohybuje ve čtvercové mřížce. Na některých polích jsou plechovky, které má posbírat, případně zdi nebo díry. Vytvořte genetický algoritmus, který bude vytvářet navigační kód pro robota. Cílem je, aby robot posbíral v omezeném čase co nejvíce plechovek. Podrobněji rozebírá tento námět Mitchell (2009).

E Návodné otázky

K čemu jsou počítače? Mohou vám dát pouze odpovědi. (P. Picasso)

Umět položit správnou otázku ve správnou chvíli je jedna z klíčových dovedností nejen při modelování komplexních systémů. Pro inspiraci uvádíme výběr otázek, nad kterými může být vhodné se zamyslet.

Komplexní systém

Následující otázky využijeme, pokud máme komplexní systém, kterému chceme porozumět.

- Zpětné vazby: Jaké jsou nejdůležitější zpětné vazby? Které zpětné vazby dominují? Jaká je struktura zpětnovazebních cyklů?
- Řízení: Existuje centralizované řízení?
- Náhoda: Jaká je role náhody v systému? Může mít náhoda, vlivem pozitivní zpětné vazby, důležitý dopad na vývoj systému?
- Účel: K čemu systém slouží? Jaké jsou jeho cíle? Jde o vědomé cíle?
- Různé pohledy: Zkuste se na systém podívat z různých pohledů: z pohledu různých podsystémů, z nadhledu, z pohledu konkurenta, z pohledu návrháře, který má podobný systém vybudovat od začátku. . .
- Podstata: Jaká je podstata tohoto systému? V čem se liší od jiných podobných systémů? Dokážeme charakteristické rysy zachytit jednoduchým modelem, na kterém by to šlo ilustrovat?

Modelování

Následující otázky využijeme v jednotlivých fázích modelování.

- Formulace problému: Jaký problém řešíme? Proč je to problém? Jak daleko do minulosti (budoucnosti) potřebujeme uvažovat?
- Základní návrh modelu: Jaké budou okraje modelu (do šířky, do hloubky)? Jaké budou klíčové prvky modelu (proměnné, agenti, objekty)? Jaké jsou klíčové děje, které ovlivňují chování systému (a potažmo tedy i modelu)?
- Budování modelu: Jaký použít nástroj? Jaká je nevhodnější reprezentace jednotlivých prvků modelu? Není potřeba se vrátit a přeformulovat cíl modelu?

- Verifikace a validace: Reprodukují model chování reálného systému? Chová se model realisticky při extrémních podmínkách? Odpovídá struktura modelu struktuře reálného systému? Jsou jednotky konzistentní?
- Simulace a analýza: Jak se model chová při změnách parametrů? Které parametry jsou nejdůležitější? Jaké jsou efekty různých zásahů do systému?
- Sumarizace výsledků: Podařilo se najít odpověď na původní problém? Plynou z modelování a simulace nějaké závěry? Jaké? Je potřeba model rozšířit? Proč? Jak by to bylo možné?