

6. SLOŽITÉ ADAPTIVNÍ SYSTÉMY

6.1 Adaptační složitých systémů

Složité adaptivní systémy sdílí určité klíčové vlastnosti (nelinearitu, složitou směs pozitivních a negativních zpětných vazeb, emergenci, kolektivní chování, spontánní organizaci, hierarchickou strukturu a pod.). Každý hierarchický (vícestupňový, víceúrovňový) systém je složen z elementů jednodušších (podsystemů). Tyto podsystemy mohou být ovšem tvořeny z dalších podsystemů nižšího řádu, tyto z dalších podsystemů ještě nižšího řádu atd. Jednotlivé organizační stupně nazýváme též hladiny (úrovně) systému. Vztahy uvnitř hierarchického systému můžeme rozdělit na horizontální a vertikální. Horizontální vztahy jsou vztahy mezi podsystemy ležícími na stejné organizační úrovni, vztahy vertikální pak vztahy mezi podsystemy na různých organizačních úrovních. Definování různého charakteru vztahů na různých organizačních hladinách má zásadní význam. Se zvyšující se vertikální organizovaností se objevují (emergují) nové vztahy, které na nižších organizačních hladinách neexistovaly, tzn. objevují se i kvalitativně nové vlastnosti, které nemají podsystemy. Pro různé organizační úrovně je nutné použít metody, které jsou dané hladině jevů adekvátní. Hierarchické uspořádání umožňuje uplatnění tzv. stavebního principu, kdy z těžších prvků můžeme tím, že je dáme do různých vztahů, vytvořit systémy kvalitativně odlišné. Význam stavebního principu je hlavně ekonomický. Např. buňce stačí pouze dvacet metabolických drah pro syntézu dvaceti hlavních aminokyselin k tomu, aby vytvořila prakticky neomezené množství bílkovin. Totéž platí pro nukleotidy, které kódují celou rozsáhlou genomovou paměť. Všechny organismy mají společné základní vlastnosti, které je charakterizují jako živé soustavy. Různé organismy se navzájem liší především složitostí jejich organizace (organismy nebuněčné – viry, organismy jednobuněčné – mikroorganismy a mnohobuněčné organismy).

Tvorba složitě organizovaných hierarchických systémů probíhá stupňovitě, postupným vytvářením relativně stabilních, stále vyšších celků. Doba potřebná k vytvoření konečného složitě celku se zkrátí nebo je postupná výstavba dokonce podmínkou pro jeho vytvoření v reálném čase. Při postupné výstavbě je dána možnost eliminovat chyby, které náhodně na úrovni nějakého podsystemu vznikají. Pravděpodobnost, že vznikne systém o správné konečné struktuře, se tak podstatně zvyšuje oproti „jednorázové“ syntéze systému.

Systémy se samoorganizací (např. ekosystémy) mají možnost měnit svoji strukturu pro dosažení vyšší adaptability a tím i své stability. Systémy s reprodukcí mohou nahrazovat původní systém novým systémem a systémy s autoreprodukcí mají schopnost vytvořit sebe sama z materiálu a energie okolí. Z hlediska struktury se systémy dělí na systémy jednostupňové a vícestupňové (hierarchické). V vícestupňových systémech (např. vícestupňová regulace) se vždy setkáváme s principem redukce informací směrem od nižších center k centrům vyšším.

Některé fluktuace mohou posunout systém daleko od rovnováhy a může současně dojít ke zvýšení organizovanosti soustavy. Tyto otázky řeší moderní teorie termodynamiky, která se zabývá nevratnými termodynamickými ději vzdálenými od rovnováhy. Je-li pak informace vzniklá náhodnou fluktuací zapsána do vnitřní paměti systému (např. genů), může dojít k dalšímu zvýšení stability systému. Tyto systémy nazýváme podle Prigogina systémy disipativní, které mohou díky stabilitě vnitřní informace udržovat stacionární stav, který je daleko od rovnovážného stavu, přičemž mohou zvyšovat míru své organizovanosti (negentropie).

U disipativních systémů vznikají makroskopické struktury, které nejsou jednoznačně odvoditelné z chování prvků (např. molekul) vytvářejících systém. Vytváření uspořádaných struktur není anomálií, ale inherentní vlastností disipativních systémů. Dokud otevřeným

systemem protéká energie, probíhá zvyšování uspořádanosti systému takovým způsobem, který nedovoluje odvodit jeho budoucí vývoj ani rekonstruovat zpětně minulý vývoj. Disipativní systém má jedinečnou historii – evoluci, kterou nelze vypočítat. Pro optimalizaci složitých systémů se používají evoluční algoritmy, které vycházejí ze základních principů evoluce přírody.

Evoluční algoritmy (EA) jsou velice účinné optimalizační algoritmy, které vycházejí ze znalostí přírodní genetiky a jejích zákonů. Evoluční algoritmy se obvykle dělí na genetické algoritmy, genetické programování a evoluční strategie.

Další vývoj a aplikace genetických algoritmů mohou být podstatně ovlivněny pochopením některých zatím neznámých přírodních principů evoluce. Člověk zatím zdaleka není schopen využít všechny principy, které používá příroda, neboť je zatím nepochopil nebo si neuvědomil jak je použít ke svému prospěchu. V poslední době je snaha využít evoluční principy pro návrh i technických prostředků (hardwaru). Na tuto oblast se zaměřují některé konference (evolving hardware systems, evolutionary hardware design, self-replicating hardware, self-repairing hardware, embryonic hardware, DNA computing a pod.).

Adaptace složitých biologických systémů probíhá neustále a je podmíněna evolučními principy přírody. Biologické principy evoluce tvoří základ pro vývoj evolučních algoritmů, které jsou součástí Soft Computing. Evoluční algoritmy patří mezi moderní metody optimalizace systémů, a to nejen technických ale i biologických, ekonomických atd. Optimalizační problémy se vyskytují v každém oboru lidské činnosti. Každodenně řešíme řadu problémů, jak něco udělat co nejlepším způsobem. Optimalizační problém vznikne v situaci, kdy je nutno vybrat nějakou variantu řešení. Pochopitelně se snažíme vybrat tu variantu řešení, která je pro nás nejvýhodnější. Hledáním nejlepší varianty řešení vznikne optimalizační problém, který lze obvykle řešit několika optimalizačními metodami. Abychom mohli optimalizační problém matematicky formulovat, je třeba sestavit matematický model situace. Dále potřebujeme mít možnost porovnat různé varianty řešení a vybrat pak nejlepší variantu. Model reálné situace (reálného objektu) je vždy zjednodušen, tj. matematicky zpracovatelný model situace nepopisuje věrně realitu a naopak, skutečnosti blízký model nebude matematicky zpracovatelný.

Klasické genetické algoritmy (GA) používají operace selekce, křížení a mutace pro simulaci procesu reprodukce. Evoluční strategie obvykle vytvářejí potomky pouze modifikací (např. mutací) jednoho rodiče, tj. nemusí používat operaci křížení. U genetického programování mohou jednotlivé geny kódovat proměnné i funkce, zatímco geny u GA kódují pouze parametry účelové funkce. Hledanou funkci u genetického programování vyjadřujeme pomocí syntaktických stromů. Genetické programování je vhodné např. pro symbolickou regresi. Vzhledem k rozmanitosti řešených optimalizačních problémů, neexistuje obecně použitelný optimalizační algoritmus. Jedná se vždy o algoritmus, který je problémově závislý, tj. více či méně vhodný pro danou účelovou funkci. Evoluční optimalizační algoritmy nejsou vhodné pro aplikace, kdy lze snadno zjistit gradienty účelové funkce nebo účelová funkce je výpočtově velice náročná. Kombinací neevolučních optimalizačních metod (např. simulované žíhání, metoda zakázaného hledání „tabu search“, horolezecký algoritmus „hill climbing“ atd.) a evolučních optimalizací vzniknou hybridní algoritmy. Jedinec (agent) s nejlepším dosaženým ohodnocením (fitness) je považován za řešení problému.

Evoluční proces prohledávání prostoru potencionálních řešení vyžaduje najít kompromis (rovnováhu) pro dosažení dvou následujících cílů:

- a) co nejrychleji najít nejbližší (většinou lokální) řešení v malém okolí výchozího bodu,
- b) co nejrychleji najít globální řešení.

Jednotlivé metody se liší tím, který cíl preferují. Následující metody jsou seřazeny od metod směřujících k lokálnímu řešení až k metodám prohledávajících celý prostor řešení. Posloupnost metod je následující: „horolezecký“ algoritmus, tabu search, simulované žíhání, evoluční strategie, genetické algoritmy. Vzhledem k řešeným problémům, bude dále pozornost věnována zejména genetickým algoritmům.

Další vývoj a aplikace genetických algoritmů mohou být podstatně ovlivněny pochopením některých zatím neznámých přírodních principů evoluce, proto je v následujících kapitolách věnována velká pozornost biologickým mechanismům evoluce. Člověk zatím zdaleka není schopen využít všechny principy, které používá příroda, neboť je zatím nepochopil nebo si neuvědomil jak je použít ke svému prospěchu. V poslední době je snaha využít evoluční principy pro návrh i technických prostředků (hardwaru). Na tuto oblast se zaměřují některé konference (evolving hardware systems, evolutionary hardware design, self-replicating hardware, self-repairing hardware, embryonic hardware, DNA computing a pod.).

V práci je zvýšená pozornost věnována problematice paralelních a hybridních genetických algoritmů.

6.2 Biologické kořeny evolučních algoritmů.

První evoluční teorii vytvořil Jean Baptiste de Lamarck. Evoluci vysvětloval schopností změn živých organismů, a to postupně po mnoho generací zděděním struktury (např. silných svalů), která se stává větší a lépe vyvinutou v důsledku trvalého používání nebo naopak zmenšenou vlivem nečinnosti. Podle dnešních poznatků většina evolučních změn výše popsaným mechanismem produkována nebyla, existuje však nepřímá možnost evoluce pomocí sekundární mutace. Lamarckova teorie byla v širokém měřítku špatně interpretována jako pouhá dědičnost získaných znaků, nebo také zesměšňována jako změny, které se organismu vyplnily na jeho přání.

Podle Darwinovy teorie založené na přírodním výběru má vznik většího počtu jedinců, než je okolní prostředí schopné uživit, za následek vznik konkurence a "boj o přežití". Pokud ve skupině existují dědičné odchylky, potom v rámci dané populace přežijí jedinci s výhodnějšími odchylkami a budou se dál rozmnožovat na úkor jedinců s méně vhodnými vlastnostmi. Díky tomu přežijí nejsilnější jedinci, takže daný biologický druh se postupně adaptuje na okolí. Změnám životního prostředí se tak biologické druhy postupně přizpůsobí.

Chybějící článek v Darwinově teorii doplnil Gregor Mendel, který svou práci publikoval ve stejném roce, kdy vyšel Darwinův *Vznik druhů*. Darwinovi tato publikace přinesla okamžitě slávu, kdežto Mendelova teorie, která ještě lépe zapadá do modelu evoluce, více než čtyřicet let ležela v archivech a byla znovu objevena na přelomu našeho století. Sám Darwin obdržel jeden výtisk Mendelovy publikace, odložil ji však do knihovny a nikdy se do ní nepodíval [4]. Mendelova teorie se obvykle podává ve formě dvou zákonů: zákona segregace, který popisuje rozdělení alel při vzniku gamet, a zákona volné kombinovatelnosti, který vysvětluje, že se alely jednotlivých genů rozdělují do zárodečných buněk zcela náhodným způsobem. Mendelova genetika se vztahuje k vzorům dědičnosti organismů se sexuální reprodukcí, a to s více než jedním chromozómem (diploidní organismy). U diploidních organismů chromozómy existují v párech (viz paměť Ia, Ib na obr.6.1). Každý z obou chromozómů pochází od jednoho z rodičů, nezáleží na tom, zda dominantní alela pochází od matky nebo otce. Pohlaví je určeno rozdíly v chromozómech, přičemž v přírodě existuje v tomto směru velká rozmanitost. U lidí, jak je všeobecně známo, žena má dva chromozómy X a muž má jeden chromozóm X a jeden Y.

Termín „mem“ se poprvé objevil v roce 1976 v knize „Sobecký gen“ Richarda Dawkinse [41]. Termínem „sobecký“ je myšleno, že geny konají vše pouze pro vlastní

prospěch, tj. zajímají se především o vlastní replikaci. Geny pouze chtějí, aby přešly do další generace. Geny se nacházejí v chromozomech, zatímco memy mohou být uloženy v mozku, v knihách, na stránkách Internetu atd. (viz obr.6.1) a jsou šířeny imitací. Hodně memů (kulturního dědictví) je přenášeno z rodičů na děti. Rodiče učí od malička svoje děti pravidlům vlastní společnosti (např. mateřský jazyk, morálku, náboženství atd.). Memy tak mohou být předávány horizontálně a mohou cestovat nezávisle na genech. Dawkins také zavedl důležité rozlišení mezi „replikátory“ a „nosiči“, tj. geny a tělesnou schránkou. Memy mohou přeskokovat z mozku do mozku pomocí procesu imitace. Memy zahrnují celou slovní zásobu jedince, písničky, příběhy které zná, zvyky, pravidla chování.

Geny jsou instrukce pro tvorbu proteinů, které jsou uloženy v buňkách těla a jsou šířeny reprodukcí (paměť I). Jejich soutěžení řídí evoluci biologického světa. Memy jsou instrukce pro šíření chování, uložené v mozku (paměti II) a předávané imitací. Jejich soutěžení řídí evoluci ducha (mysli). Memy mohou být uloženy v paměti lidstva (paměť III), tj. v knihách, obrazech, WWW stránkách na Internetu. Lidé mohou získat nové memy také z televize, divadla, kina, rádia, a to daleko dříve než předají své geny. V současné době existuje celá řada možností jak horizontálně přenášet memy (šířit gramotnost) pomocí klasického a mobilního telefonu, faxů, CD, kazet, počítačové sítě atd. Dawkins chápe organismus (tělo) jako „nosič“ genů, který je fyzicky transportuje a chrání. Chování může být řízeno jednoduchými pravidly, uloženými v paměti II (pravá část), jako „Buď hodný k těm, kteří tě imitují“, „Buď hodný k dětem“, „Podporuj své nejbližší kulturní příbuzné“ atd. I současné sexuální chování je ovlivňováno kulturou a náboženstvím, tj. je řízeno i na základě memů i genů.

Evoluce memů probíhá v současné době mnohem rychleji než evoluce genů. Vnitřní genově podmíněná reakce organismu (hormonální) na problémové situace (stress) odpovídá současné úrovni evoluce genů, a protože je řešena i vědomě na úrovni mozku (memů), dochází ke konfliktu, který se v konečném důsledku projevuje snížením obranných mechanismů imunitního systému, a tím ohrožením života. Lze tak vysvětlit i nadměrnou obezitu některých etnických skupin, kdy energetický metabolismus je geneticky nastaven na šetření energií a její uložení pro případ potravinové nouze, s níž se musel vyrovnávat organismus v pravěku. Geny se nestačily adaptovat na trvalý potravní nadbytek. Celková (integrovaná) evoluce probíhá, jak je patrné z obr.1.1, na úrovni genů a memů, a to ve třech pamětech I, II, III (v genech, mozku a vnější paměti lidstva) a ve zbytku přírody (paměť IV). Z obr. 6.1 je též patrné místo pro teorie jednotlivých autorů. Celkovou evoluci tak nelze vysvětlit pouze jedním principem, ale pouze na základě jejich spojení. Jednotlivé teorie mohou být různě kombinovány a použity pro optimalizaci systémů. Např. evoluce memů se používá v kulturních algoritmech, Baldwinův efekt u systémů s učením.

6.3 Genetické algoritmy

Myšlenka systémů simulujících přírodní evoluci je stará jako počítače samy. Již geniální americký matematik Friedman, který se mimo jiné podílel na rozluštění japonského vojenského kódu, nazývaného Američany „purple“ (1940-1941), v roce 1959 uvažoval o tom, že simulace principů mutace a selekce by mohla být schopna zkonstruovat „thinking machines“. Uvažoval, že na tomto principu by mohl pracovat program hrající hru šachy. V 60. letech prezentoval L. Fogel serii článků obsahujících studie, kde používal metodu *evolučního programování* pro vývoj systémů umělé inteligence. Genetické algoritmy prezentoval poprvé J. Holland jako účinný prohledávací mechanismus pro adaptivní systémy umělé inteligence. Definoval operátor *křížení* (crossover operátor) a operátor *inverze*. Operátor křížení je považován za hlavní rozlišovací znak genetických algoritmů, které tento rekombinační operátor považují za primární. Ten pravý rozruch, který vzbudil značný zájem o GA,

způsobilo první vydání knihy Hollandova studenta Davida Goldberga *Genetic Algorithms in Search, Optimization, and Machine Learning*. Tato kniha, ve které je detailně popsán standardní GA, včetně příkladů implementace, je považována za „bibli“ genetických algoritmů a odkaz na ni najdeme téměř ve všech dalších publikacích. Po jejím vydání v roce 1989 prudce narostl zájem o tuto oblast vědy zvané *evolutionary computing*, která je nyní součástí *soft computing* (rozšířené o fuzzy logiku, neuronové sítě a fraktály). Po roce 1989 nastává exponenciální nárůst publikací, které jsou věnovány problémům řešitelným evoluční optimalizací.

Abychom mohli popsat činnost GA musíme si uvědomit spojení GA s řešeným problémem. To představuje dva mechanismy:

- a) způsob přiřazení řešeného problému (zakódování pomocí genů) k chromozómům,
- c) ocenění každého chromozómu, které udává cenu chromozómu vzhledem k řešenému problému (fitness), což umožňuje provést výběr chromozómu pro další populaci.

Slovní popis GA je následující:

krok 1. Vytvoř náhodně počáteční populaci A jedinců (chromozómů),

krok 2. Oceň každý chromozóm dané populace (stanovení kvality jedince pomocí účelové funkce),

krok 3. Vytvoř nové chromozómy procesem reprodukce; tj. aplikuj operátor selekce, mutace a křížení (rekombinace).

krok 4. Vymaž staré jedince v staré populaci, aby se vytvořil prostor v paměti pro novou populaci.

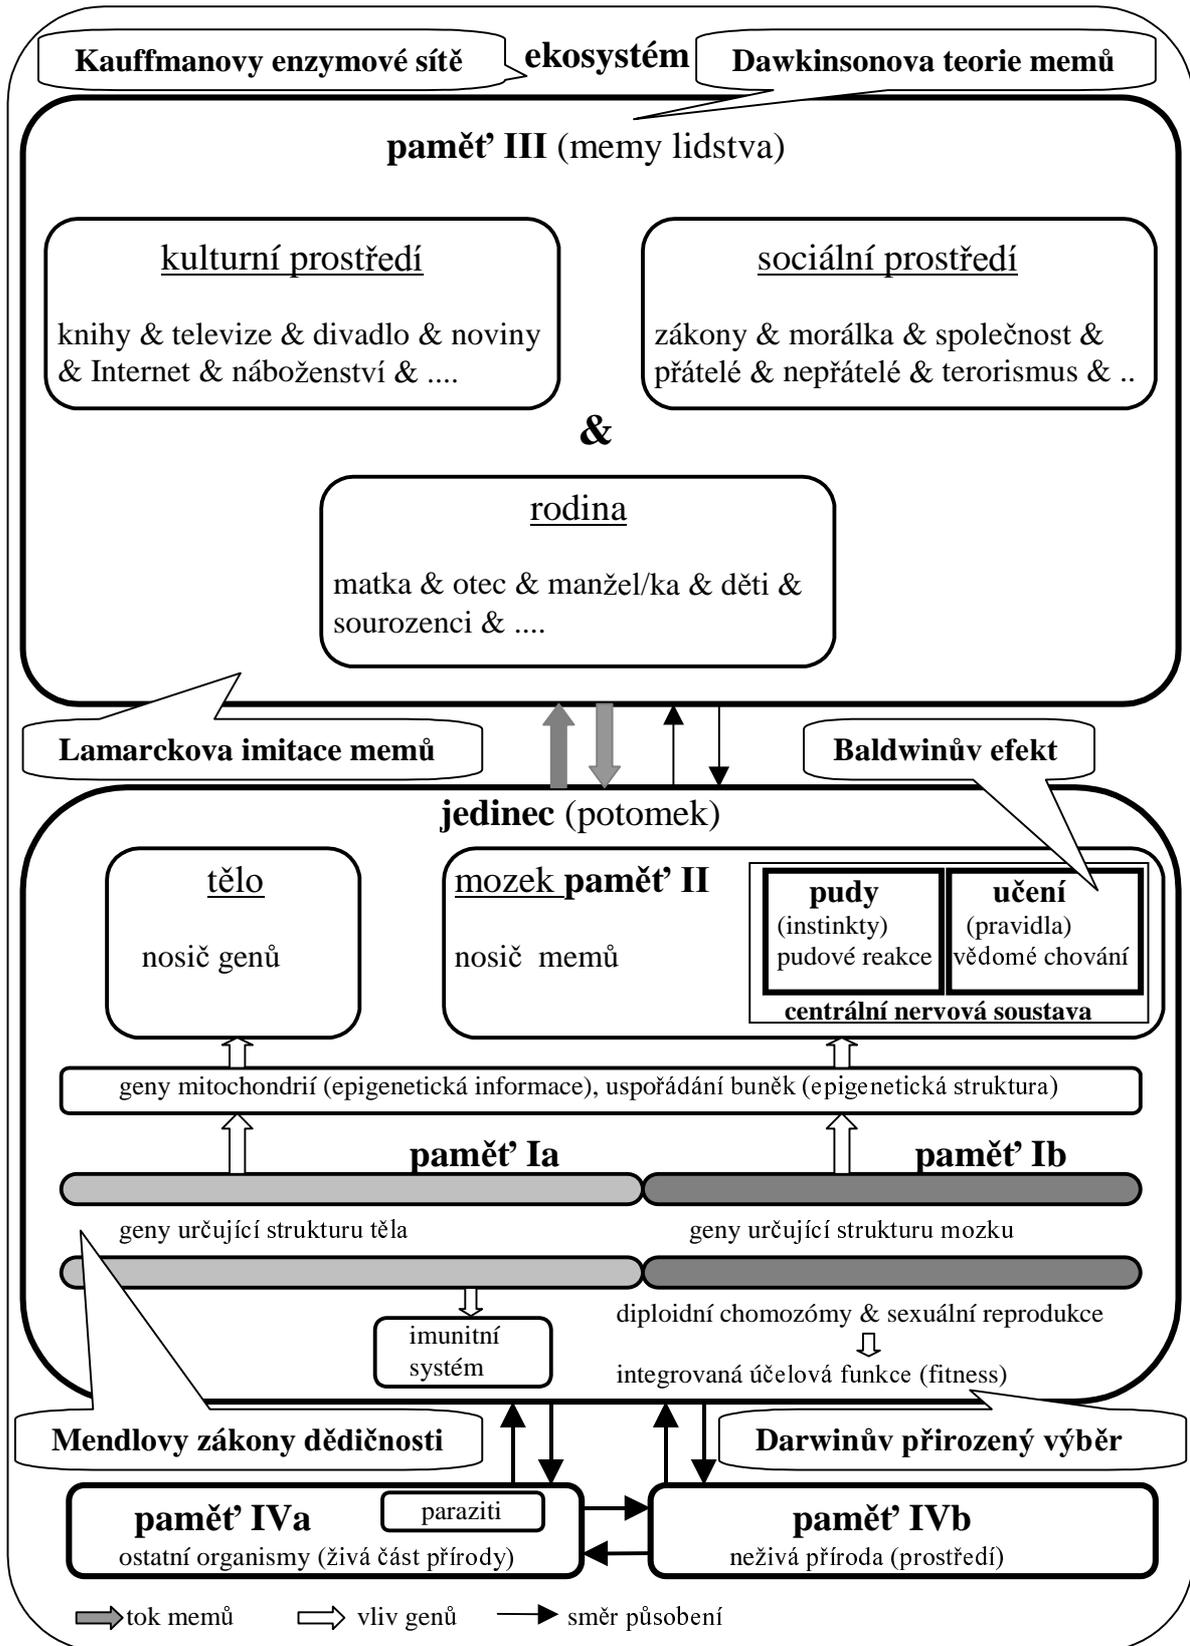
krok 5. Oceň nové chromozómy a vlož je do populace.

krok 6. Jestliže je splněna ukončující podmínka, tak vyber nejlepší chromozóm jako řešení problému, jinak běž na krok 3.

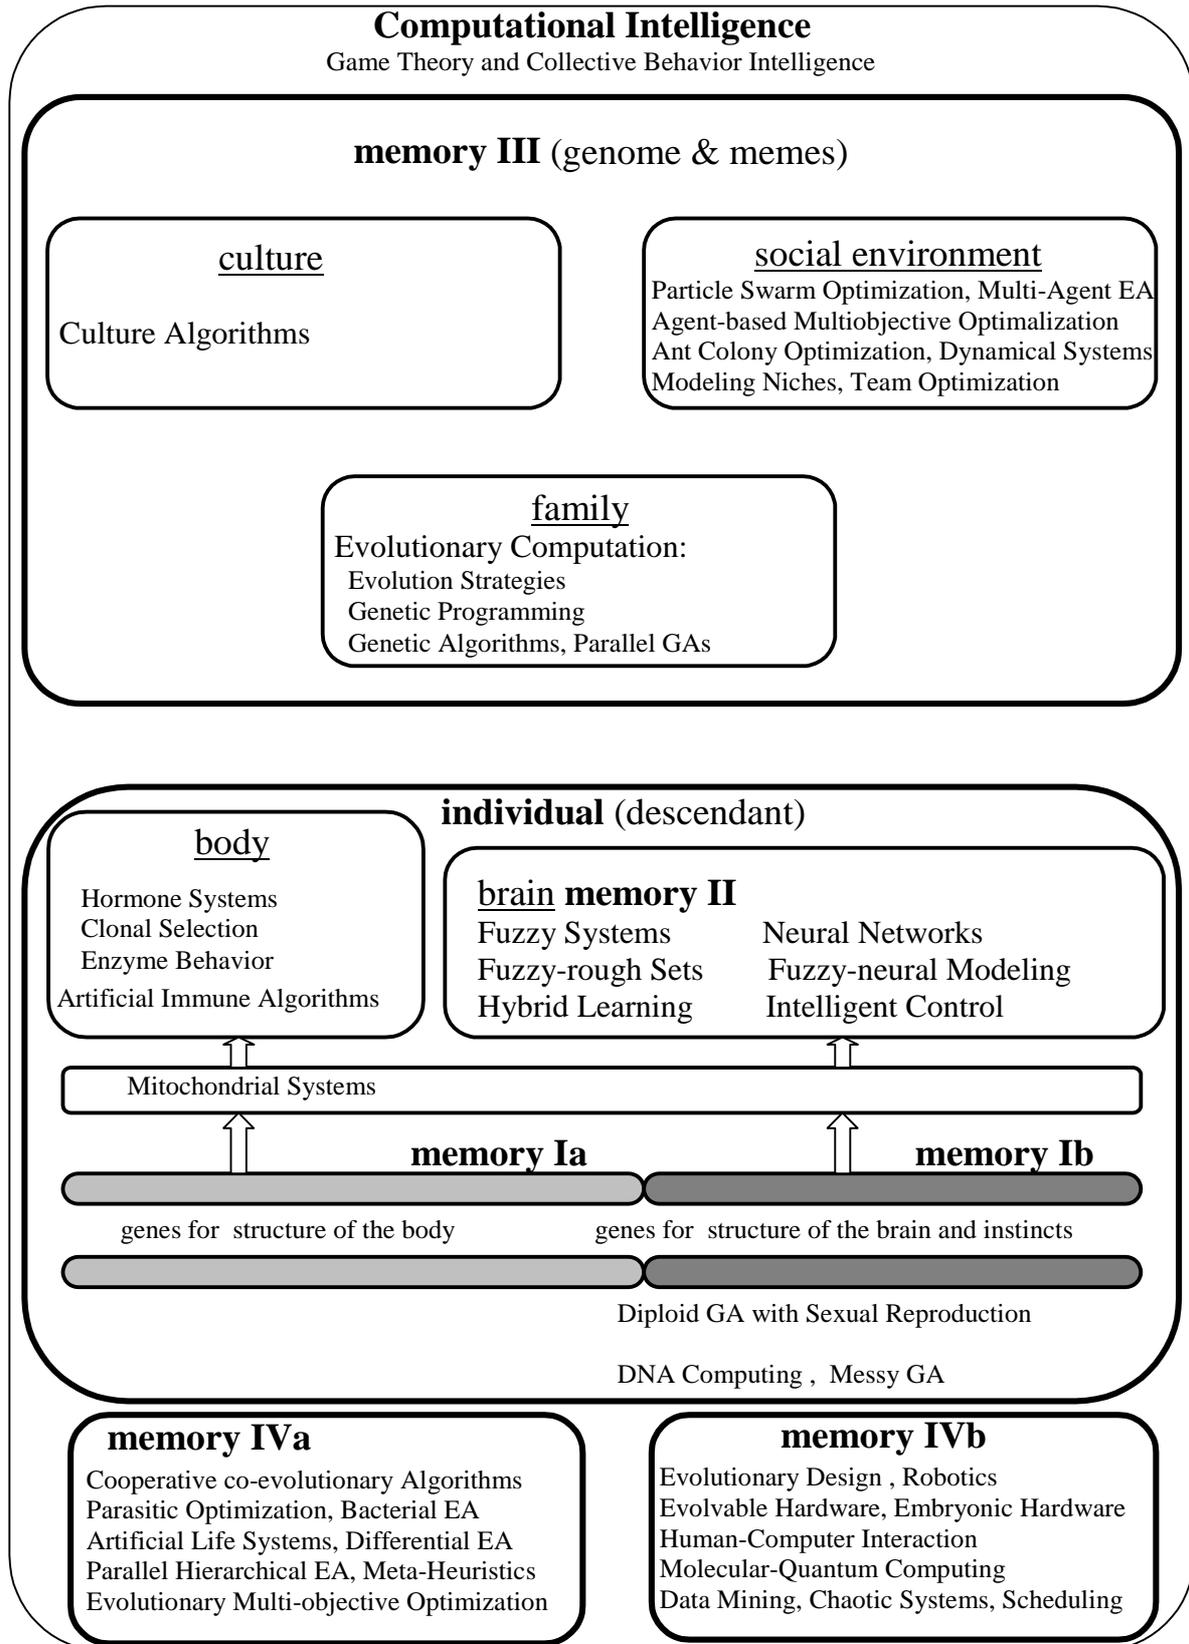
Genetický algoritmus začíná inicializací populace. Obvykle bývá všech N chromozómů inicializováno náhodně jako bitový řetězec. Slovem „náhodně“ je vytvoření počáteční populace pomocí pseudonáhodného (obvykle kongruenčního) generátoru náhodných čísel. V některých případech je však vhodné zvolit jiný druh inicializace, neboť zcela náhodné počáteční nastavení může způsobit zbytečnou ztrátu času, neboť mohou být generovány nefunkční chromozómy, které nemají smysl pro řešený problém. Jako typický příklad lze uvést problém obchodního cestujícího (TSP), kde je vhodné zabránit duplicitě v chromozómu. V případě, že tak neučiníme, je třeba do fitness funkce zakomponovat postih za tento prohřešek (penalty function). Např. u TSP musíme ošetřovat duplicitu nejen v inicializaci, ale i v operátorech křížení a mutace. Nejběžnější používané operátory jsou následující: selekce, křížení a mutace.

6.4 Varianty genetických algoritmů

Od roku 1989, kdy Goldberg [45] svojí publikací upozornil na možnost použití genetických algoritmů, a to nejen pro biologické simulace, ale i pro technické aplikace, nastává exponenciální nárůst publikací týkajících se teoretických problémů GA, tak i jejich praktických aplikací. Zpočátku byla velká pozornost věnována různým variantám standardního GA, tj. vlivu různých variant základních operátorů selekce, křížení a mutace. Velice důležitým problémem je presentace problému, tj. zakódování problému pomocí jednotlivých genů. Neexistuje universální předpis jak provést presentaci problému, neboť nejvhodnější zakódování úlohy je problémově závislé. Např. zakódování problému obchod-



Obr. 6.1 Integrovaná evoluce genů a memů



Obr. 6.2 Transformace obr. 6.1 do struktury Soft Computing

ního cestujícího TSP se diametrálně liší od zakódování fuzzy regulátoru. Geny mohou být bity, celá čísla nebo reálná čísla. Základním předpokladem pro použití GA je možnost rychlého výpočtu účelové funkce z údajů uložených v jednotlivých genech.

Cílem optimalizace může být nalezení maxima nebo minima účelové funkce. Pro potřeby GA je nutné účelovou funkci při hledání minima upravit na „fitness“ funkci, u které hledáme maximum. Např. fitness funkci lze v případě minimalizace účelové funkce vytvořit následovně: $\text{fitness} = 1/(1 + \text{účelová funkce})$. Dosahované výsledky optimalizace též silně závisí na nastavení parametrů genetického algoritmu, tj. velikosti populace, pravděpodobnosti křížení, pravděpodobnosti mutace atd. Můžeme použít i tzv. metaoptimalizaci, kdy nastavení parametrů GA je nastavováno např. jiným GA ve vyšší vrstvě nebo pomocí fuzzy pravidel. Běžně se počáteční populace generuje náhodně. Pro urychlení výpočtu je velice výhodné generovat počáteční populaci pomocí heuristik, tj. využít maximálně informace o řešeném problému

Velkou skupinu genetických algoritmů tvoří tzv. hybridní GA, kdy se kombinují jiné známé metody s GA. Například pomocí jiných negenetických metod optimalizace (např. simulovaného žíhání) generujeme počáteční populaci a potom pomocí GA se snažíme najít ještě lepší řešení. Jinou variantou je hierarchická struktura GA, kdy na nejnižší úrovni GA se nacházejí skupiny paralelně běžících negenetických metod.

Populační způsob prohledávání stavového prostoru obsahuje již ve svém principu paralelnost, kterou lze využít, pokud je výpočet prováděn na odpovídajícím technickém vybavení a s příslušným programovým vybavením. Pokud řešíme velice obtížné a časově náročné problémy optimalizace je výhodné použít paralelní GA (PGA), které jsou uvedeny v následující kapitole. Velmi výrazným zlepšením klasického GA je zavedení operátoru migrace, který urychluje nalezení globálního extrému řešené úlohy. Podstata je následující. Řešená úloha je pomocí GA řešena nezávisle v několika malých populacích, z nichž někteří (např. nejlepší) jedinci předávají své genetické informace do společné populace, a tak vytvářejí bohatý genofond, který podstatně rychleji konverguje k cílovému řešení. Tato metoda byla např. ověřována na problému nalezení cesty bludištěm, kde pohyb byl omezen na dva směry (dolů a doprava), čímž byla při známém rozmístění překážek snadno patrná i lokální minima. Tak bylo možné velice snadno sledovat vliv operace migrace na úspěšnost celého řešení. Problém je sice řešitelný pomocí klasického GA také, ale za cenu podstatného zvětšení velikosti populace (rozsáhlejší genofond) a v důsledku toho dojde k podstatnému prodloužení výpočtu.

Vzhledem k tomu, že průběh práce algoritmu závisí na počáteční populaci a že chování GA je silně ovlivněno celou řadou implementačních detailů, byl vyzkoušen i tzv. víceúrovňový distribuovaný GA. V této variantě je spuštěno současně několik GA (s různou počáteční populací, s různě nastavenými parametry, s různou implementací). Za řešení úlohy se považuje řešení dosažené algoritmem hierarchicky nejvyšší úrovně. U víceúrovňových distribuovaných algoritmů se s výhodou zavádí restart podřízených algoritmů v případě, že po jistý stanovený počet iterací nedosáhnou zlepšení řešení, případně nenabídnou GA vyšší struktury žádné řešení nebo žádné jimi nabídnuté řešení není přijato. Porovnání časové náročnosti výpočtu resp. počtu iterací potřebných k nalezení řešení „obyčejným“ a distribuovaným GA (počet iterací se u víceúrovňových distribuovaných GA stanovuje podle počtu iterací provedených algoritmem v nejvyšší hierarchické úrovni) výrazně hovoří ve prospěch tohoto uspořádání. Jako významný lze označit vliv uspořádání hierarchické struktury – počet vrstev, počet algoritmů v jednotlivých vrstvách.

Hlavní přínos migrace je, že lze řešit i relativně složité problémy na PC, kde jsme ještě limitováni rozsahem paměti. Součet všech jedinců malých populací může být menší než počet jedinců jedné velké populace. Dále velice důležitou vlastností operátoru migrace je, že může

být použito paralelní zpracování řešené úlohy. Úloha může být řešena na více paralelně pracujících počítačích, které jsou zapojeny do počítačové sítě. Jednotlivé počítače reprezentují izolované malé populace, v nichž probíhá nezávislý náhodou ovlivněný vývoj. Nejlepší dosahovaní potomci jsou prostřednictvím počítačové sítě posíláni jednomu centrálnímu počítači, který obsahuje společnou populaci nejlepších jedinců. I na tomto centrálním počítači probíhá GA. Tak lze dosáhnout podstatné urychlení výpočtu i při omezených paměťových možnostech jednotlivých PC.

Při nasazení klasického GA na řešení složitějších problémů souvisejících např. s neuronovými sítěmi, se ukázalo, že GA mají celou řadu omezení. Např. nedostatkem je, že gen (váha neuronového vstupu) je tvořen na bitové úrovni. Při křížení na bitové úrovni dochází k dělení genů, čímž se produkuje mnoho nevyhovujících potomků a výpočet je zbytečně dlouhý. Problém byl řešen pomocí objektového programování, a to jak v jazyku Pascal, tak i C++. Typ genu může být zobecněn. Je možno si pak zvolit typ ve tvaru bitu, slabiky, slova nebo reálného čísla. Může být použito vícebodové křížení. Dále každý gen má stanoven svůj rozsah možných hodnot. Např. při slabikové reprezentaci genu je možné rozsah každého genu definovat v intervalu $\langle 0,255 \rangle$ nezávisle na ostatních genech, což lépe vyhovuje různým aplikacím, neboť optimalizované parametry uživatelské úlohy mají různé rozsahy jednotlivých parametrů. Možnou variantou GA může být rozdělení každé populace na dvě části: rodičů a potomků. Nejlepší rodiče neustále přežívají v jedné polovině a mohou být nahrazeni pouze lepšími potomky druhé poloviny, kteří vznikají křížením rodičů a následnou mutací. Aby proces selekce vyřazovaných potomků probíhal co nejrychleji, byla použita metoda indexového třídění. Jednotlivci v populaci jsou pouze označováni a nejsou přemísťováni v paměti počítače. Oceňování již označených rodičů se v následující generaci neprovádí, čímž se urychluje podstatně výpočet.

Dalším vhodným operátorem může být zavedení *omezené doby života* jedinců v populaci [55]. Činnost operátoru lze charakterizovat následovně:

1. Každý jedinec obsahuje čítač, představující *věk* jedince. Na začátku života jedince je věk nastaven na hodnotu 0. Vznik nového jedince je pomocí generátoru náhodných čísel nebo vznik potomka operací křížení.
2. Každý jedinec populace *stárne*, operace stárnutí je realizována inkrementací věku každého jedince po každé iteraci. Jedinci, jejichž věk přesáhne limit doby života, umírají, jsou z populace odstraněni a nahrazeni novými náhodně vygenerovanými jedinci (s věkem 0).
3. Věk jedince nemá vliv na výběr rodičů pro křížení ani na mutaci. Opačně platí, že mutace chromozomu jedince neovlivňuje věk tohoto jedince.
4. výhradně způsobem dle bodů 1 a 2. Samotný čítač věku nepodléhá křížení ani mutaci, jeho hodnota je měněna
5. Pro zajištění monotónnosti si GA zapamatovává nejlepší dosud nalezené řešení. V populaci se ovšem nemusí vyskytovat jedinec, který je nositelem tohoto řešení (mohl být odstraněn při překročení věkového limitu); v tomto případě se nejlepší řešení neúčastní reprodukce.

Klasický GA vykazuje některé vlastnosti sexuální reprodukce (potomek vzniká křížením – smísením genetické informace dvou rodičů) a některé vlastnosti reprodukce asexuální (používají se haploidní chromozomy, nerozlišuje se pohlaví rodičů), a není tedy přímým modelem přírodního evolučního procesu. To samozřejmě neznamená, že by i v této základní variantě nemohl představovat použitelnou metodu pro řešení určitých typů problémů. Otázkou je, jak bude přibližování nebo naopak vzdalování se od přírodních analogií ovlivňovat chování GA.

Rozborem vlastností mechanismů přírodní evoluce lze dospět k názoru, že GA používající sexuální reprodukci by měly vykazovat velmi dobré vlastnosti při řešení problémů s časově proměnnou účelovou funkcí. GA se sexuální reprodukcí využívá další analogii živé přírody. V přírodou používané sexuální reprodukci vzniká diploidní potomek spojením haploidních pohlavních buněk diploidních rodičů. Pro napodobení této strategie v genetickém algoritmu je třeba uvážit, jaké modifikace klasického GA může modelování sexuální reprodukce přinést. Prvním důležitým rysem je existence diploidních chromozomů a související problematika dominance a recesivity. V GA, který modeluje sexuální reprodukci, je populace rozdělena do dvou stejně početných částí, jedna část představuje samčí a druhá samičí část populace. Příznak příslušnosti k pohlaví je uložen ve speciálním genu. Tento „pohlavní“ gen podléhá křížení stejně jako ostatní části chromozomu, hodnota vzniklá křížením určuje, do které části populace bude jedinec zařazen. Pohlavní gen nepodléhá mutaci. Operátor výběru rodičů je modifikován tak, aby potomek byl vytvářen křížením dvou rodičů, kde každý rodič je z jiné části populace.

V současné době existuje velký počet dalších variant GA. Není jednoduché je všechny sledovat a mezi sebou porovnat, vzhledem k tomu, že jejich autoři je prezentují na rozdílných problémech a jejich počet neustále narůstá. Obvykle je využita jiná část integrovaného evolučního algoritmu (viz. obr.6.1). Tak vznikají např. „kulturní“ nebo „memové“ algoritmy. Dále lze různým způsobem s GA kombinovat fuzzy logiku a neuronové sítě. Parametry GA lze adaptivně nastavovat v průběhu výpočtu GA pomocí fuzzy pravidel. Nadějně se zdají např. Bayesovské algoritmy. Zvláštní skupinu tvoří GA pro vícekriteriální optimalizaci. Další skupiny tvoří *messy* GA, multiploidní GA, DNA algoritmy, GA se sexuální reprodukcí atd. Uvedený přehled genetických algoritmů není úplný, ale obsahuje základní směry GA. Ve své práci jsem se zaměřil zejména na paralelní, hybridní a diploidní genetické algoritmy.

6.5 Paralelní genetické algoritmy.

Paralelní genetické algoritmy (PGA - Parallel Genetic Algorithms) jsou výkonné stochastické prohledávací strategie inspirované přírodou, dovolující řešit větší a složitější problémy, přičemž často vedou rychleji k řešení a současně konvergují i k lepším výsledkům. Používají se tři modely PGA: „farmářský“ model (farming model), migrační model a difusní model. Někdy se pro poslední dva typy PGA používá název distribuované genetické algoritmy (DGA). PGA pracuje s nezávislými podmnožinami populace, v nichž probíhá evoluce částečně izolovaně (dále jen podpopulace). Pojem paralelní nebo sekvenční se vztahuje k populačním strukturám, nikoli k hardwaru, na kterém jsou genetické algoritmy implementovány. Při simulaci PGA mohou být procesy nad podpopulacemi prováděny současně v procesorech multiprocessorového zařízení nebo multiplexně v programových blocích počítače s jedním procesorem. V následujícím pojednání se pod pojmem procesor rozumí jednotka provádějící proces nad populací či její podmnožinou bez ohledu na použitý způsob.

Migrační model simuluje proces reprodukce lépe než sekvenční GA. V přírodě může být pozorováno, že oddělené populace se vyvíjejí nezávisle. Například na izolovaných ostrovech obklopených oceánem různé populace nepodléhají stejnému selekčnímu vlivu. V důsledku přirozených bariér zde existuje více nebo méně oddělený selekční tlak na každém ostrově. Relativně náhodně se pak stane, že několik jedinců opustí svůj původní ostrov a dostane se na jiný ostrov. Migrační model tento proces simuluje rozdělením populace do určitého počtu menších podpopulací, které si čas od času vymění několik jedinců. Populace je distribuována v daném počtu podpopulací, proto se pro tento druh GA můžeme setkat v literatuře s názvem „distribuované genetické algoritmy“. Nad každou podpopulací běží normální sekvenční GA s

místním řízením. Po určitém počtu generací (migrační interval, migrační rychlost) dojde k migraci, tj. výměně genetické informace mezi podpopulacemi. Distribuce populace do určitého počtu podpopulací a migrační proces jsou dvě podstatné odchylky, kterými se tyto algoritmy odlišují od standardního GA. Dělení populace na podpopulace podporuje rozmanitost genetického materiálu a tím se snižuje sklon k předčasné konvergenci celé populace do lokálního extrému. Migrace přináší nový genetický materiál do podpopulací a šíří tak dobré vlastnosti v celé populaci. Paralelní GA využívající migrační model se skládá z následujících kroků:

definuj počet podpopulací,
 definuj spojení mezi podpopulacemi,
 náhodně generuj počáteční podpopulace,
 oceň každého jedince ve všech podpopulacích,
 dělej (pro každou podpopulaci paralelně):
 vyber nové rodiče,
 proved' křížení,
 mutuj potomky,
 oceň potomky,
 proved' migraci, t.j. pošli několik jedinců do sousedních podpopulací a přijmi
 jedince od sousedních podpopulací (nemusí být prováděno každé generaci),
 dokud ukončovací podmínka není splněna.

Byla již navržena celá řada migračních postupů. Migrační strategie můžeme klasifikovat podle následujících hledisek:

 které podpopulace si vyměňují jedince,
 kdy budou jedinci vyměněni,
 kteří jedinci budou vybráni pro migraci,
 zda budou migrovat kopie jedinců nebo budou jedinci skutečně migrovat, tj. z jedné
 podpopulace přejdou do jiné.

Podpopulace jsou spojeny pomocí komunikační sítě. Jestliže síť poskytuje spojení každých dvou podpopulací, tj. úplná síť, pak model PGA je nazýván „ostrovním modelem“ (island model). V ostatních případech model je nazýván „stepping-stone“ modelem (podle představy, že jedinci se mohou pohybovat z ostrova na ostrov po kamenných cestách mezi nimi. U některých autorů se setkáváme s názvem ostrovní model pro obě možnosti. Neúplná síť může být např. kruhová struktura, kdy každá podpopulace má dvě sousední, s nimiž může probíhat migrace. Jiný typ neúplné sítě „žebřík“ (ladder) se vyskytuje v literatuře. Tato struktura bývá velice často používána v difusních modelech.

Migrace je nazývána synchronní, jestliže probíhá vždy po určitém pevném počtu generací. Většina migrací, které byly popsány v literatuře, je právě synchronní. Pouze několik autorů implementovalo asynchronní migraci. V těchto implementacích je vždy nový nejlepší jedinec v populaci poslán do jiných podpopulací. Tímto způsobem se migrace odehrává po rozdílných počtech generací, tj. v různých intervalech (epochách). Velmi dobří jedinci mohou svým příchodem strhnout málo vyvinuté podpopulace do lokálních extrémů. Proto jsou navrženy migrační modely s předepsanými úrovněmi chování. To znamená, že podpopulace bude připravena k migraci, když její průměrné vlastnosti dosáhnou předdefinovaných úrovní. Některé podpopulace proto budou muset čekat, dokud poslední podpopulace nedosáhne této předepsané úrovně.

Jednotlivé modely se mohou lišit výběrem jedinců, kteří jsou předmětem migračního procesu. Někteří autoři dávají přednost nejlepším jedincům, jiní náhodně vybírají

podmnožinu, která bude kopírována do jiných podpopulací. Ve většině implementací migračních modelů jsou do jedné nebo více podpopulací posílány kopie jedinců, kteří jsou předmětem migrace. Tento způsob se někdy nazývá „immigration“. U metody „emigration“ jedinci skutečně opouštějí své mateřské podpopulace a migrují pouze do jedné. Mnoho takto navržených modelů pak dává dobré výsledky, což se týká především urychlení výpočtu a kvality řešení. Např. transputerová síť se 128 procesory vykazovala lepší vlastnosti s emigrační strategií.

Jednotlivé migrační modely se liší strukturou propojení jednotlivých podpopulací. Struktura migračního modelu může být s centralizovaným, hierarchickým (stromovým), kruhovým, kruhovým centralizovaným, maticovým (mřížkovým) a toroidním uspořádáním. Velice dobré výsledky se dosahují při toroidním uspořádání, kdy každá podpopulace má stejný počet sousedů, např. čtyři. Pro toto uspořádání neexistují migrační problémy u okrajových podpopulací. Na základě našich výpočtů lze konstatovat, že stejný výkon výpočetní techniky (např. 15 počítačů propojených počítačovou sítí) dává lepší výsledky při použití víceúrovňové struktury. Např. při přechodu z dvouúrovňové struktury na čtyřúrovňovou se zkrátí doba výpočtu asi třikrát.

Migrační model s hierarchickou strukturou

Tvorba složitě organizovaných hierarchických systémů probíhá stupňovitě, postupným vytvářením relativně stabilních, stále vyšších celků. Doba potřebná k vytvoření konečného složitěho celku se zkrátí nebo je postupná výstavba dokonce podmínkou pro jeho vytvoření v reálném čase. Při postupné výstavbě je dána možnost eliminovat chyby, které náhodně na úrovni nějakého podsystemu vznikají. Pravděpodobnost, že vznikne systém o správné konečné struktuře, se tak podstatně zvyšuje oproti „jednorázové“ syntéze systému.

Analýza hierarchických systémů má mimořádný význam i pro popis regulačních obvodů. Regulační podsystem, ležící na nižší úrovni organizace, je vždy nadřazen podsystemům nižšího řádu. Nejvyšší řídicí centrum získává zpravidla omezené množství informací, které jsou pro řízení systému jako celku důležité, tj. ty, které určují především stabilitu celého systému a jeho chování navenek.

Komplexní pohled na evoluci je shrnutý v obr. 6.1, který představuje vývoj obsahu čtyř pamětí a souvislosti mezi geny a memy. Podsystemy tohoto komplexního evolučního systému tvoří základ pro vznik různých optimalizačních metod na bázi evolučních algoritmů. Obecná teorie systémů vychází z předpokladu, že všechny reálně existující objekty mají některé vlastnosti společné, bez ohledu na to, jaká je materiální podstata těchto objektů nebo zda jde o objekty neživé (např. stroj, technologie výrobního procesu), živé (organismus, ekosystém), či sociální (výrobní proces jako společenský jev, organizace školství). Cílem teorie systémů, do které patří i problémy jejich optimalizace, je tedy hledání formálně identických (izomorfních) zákonů, podle nichž se chovají systémy materiálně odlišných typů. Nalezení formálních analogií mezi systémy umožňuje dále modelování jevů (simulační či matematické), což je prostředkem studia i těch procesů, které lze empirickými metodami studovat jen velice obtížně. Systémový přístup je důležitou podmínkou pro počítačové modelování složitých procesů. Systémová věda používá vlastní pojmový aparát s exaktně definovanými pojmy. Tím vytváří dorozumivací jazyk, který je jednotný pro všechny vědní obory (fyzikální, biologické, informační, sociologické atd.) a umožňuje tak výměnu informací mezi pracovníky nejrůznějších vědních i aplikovaných oblastí, čímž je urychlen vývoj jednotlivých vědních oborů.

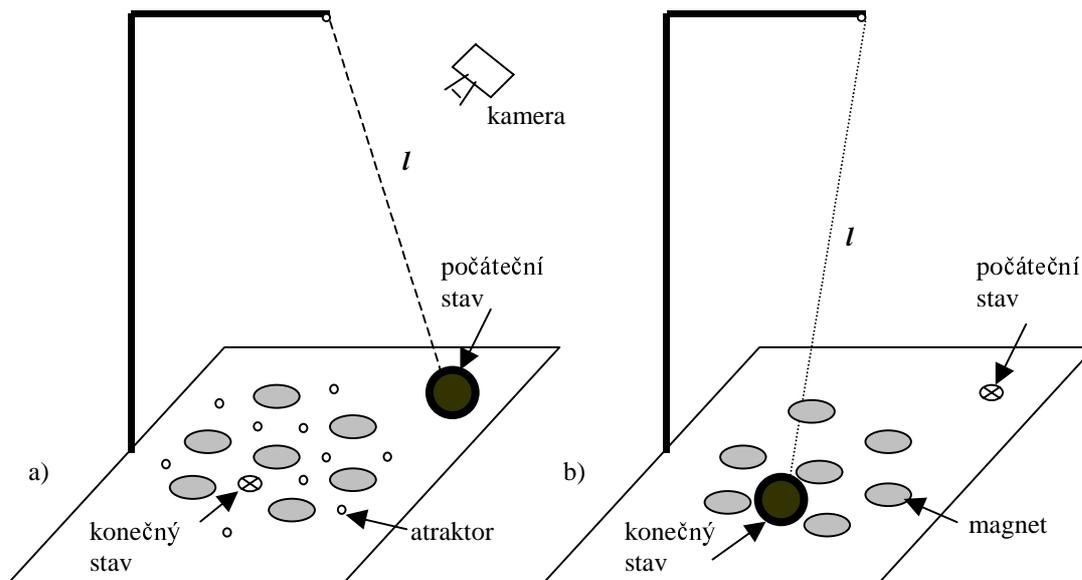
6.6 Predikce chování systémů a nalezení historie

Existují tři cesty jak postupovat ve vědě, rozvíjet matematickou teorii, provádět laboratorní experimenty a vyhodnocovat počítačové modelování. Nejlépe je, když se tyto tři cesty navzájem podporují. Např. najdeme něco zajímavého na počítačovém modelu a následně se snažíme najít teorii, pomocí které lze daný jev popsat a vysvětlit. Poté se můžeme vrátit zpět k počítači nebo do laboratoře a prověřit teorii experimentem atd. Programování pak lze chápat jako matematické umění. Srdcem matematiky je důkaz. Jakmile je nějaké tvrzení matematicky dokázáno, je jeho platnost definitivně ustanovena. V jiných vědních oborech se hypotézy experimentálně testují tak dlouho, dokud nejsou vyvráceny (pak jsou zformulovány hypotézy nové). Vědecký důkaz proto na rozdíl od matematického nemusí být definitivní a slouží k podpoře současně uznávané teorie. V roce 1976 byl poprvé výpočet na počítači součástí matematického důkazu. Jednalo se o důkaz toho, že k vybarvení jakékoliv myslitelné mapy stačí čtyři barvy, přičemž žádné dvě oblasti se společnou hranicí nemají stejnou barvu. Počítač udělal víc než pouhé zrychlení výpočtů. Počítač přispěl takovou měrou, že by bez něj nebyl důkaz možný. Současně měli mnozí matematici nepříjemný pocit, protože neexistoval způsob, jak důkaz prověřit tradičním způsobem. Gödel dokázal, že v matematice existují výroky, které jsou sice pravdivé, ale nedokazatelné. Tyto výroky nazval nerozhodnutelnými. Stejně jako v matematice existují meze, za kterými již nelze dokazovat věty, existují meze i v kvantové fyzice, tzv. Heisenbergův princip neurčitosti. Trvají-li fyzikové na velké přesnosti určení polohy, musí za to zaplatit tím, že se vzdají přesnosti informace o rychlosti předmětu. U evolučních algoritmů musíme být rádi, že jsou schopné nalézt vyhovující řešení obtížných problémů, pro které nemáme v některých případech jiné vhodnější metody. Lze je samozřejmě kombinovat s ostatními metodami (hybridní algoritmy).

Se zvyšující se organizovaností (vertikální) se u hierarchických systémů objevují (emergují) nové vztahy, které na nižších organizačních hladinách neexistovaly, tzn. objevují se i kvalitativně nové vlastnosti oproti vlastnostem subsystémů. Myšlení jako kvalitativně nový jev vzniká až po dosažení určité organizovanosti soustavy (mozku). Na úrovni jedné buňky nebo jednoduché soustavy nervových buněk je existence myšlení nemožná. Chování agentů se jako nová kvalita projeví až na chování distribuovaného řídicího systému jako celku. Obdobně některé nové jevy se při optimalizaci pomocí GA objeví až na úrovni genofondu (např. vliv diploidních chromozómů nebo vliv migrace).

I přes dosažené pozitivní výsledky optimalizací pomocí GA je jasné, že příroda používá ještě rafinovanější a přitom ne zcela odhalené principy. Většina dosud popsaných GA odpovídá pouze základním principům živé přírody, a to na úrovni nepohlavního rozmnožování s jedním jednoduchým chromozómem. Protože příroda svoje mechanismy prověřila v průběhu miliard let, je účelné se dále od ní učit. GA byl např. použit při optimalizaci návrhu plynové turbíny. V tomto případě doba návrhu byla redukována z osmi týdnů (jeden inženýr pracující sám) na dva dny za pomoci genetického algoritmu kombinovaného s expertním systémem. Paralelní GA našly uplatnění při návrhu spojů uvnitř složitých VLSI obvodů, včetně mikroprocesorů (topologické úlohy). Zdokonalování technických prostředků (počítačů) vede ke zdokonalování optimalizačních prostředků na bázi PGA, čímž se uzavírá kladná zpětná vazba vzájemného podporování. Dochází tak k prudkému nárůstu výkonu jak počítačů tak i PGA, přičemž se objevují nové výhodné vlastnosti, které nemohly vzniknout u jednoduchých izolovaných systémů.

již se nikdy neobjevila. Složitost problému si vysvětlíme na snadno představitelném modelu magnetického kyvadla (viz obr.6.3).



Obr. 6.3 Magnetické kyvadlo (psycho pendulum)

Silná stránka vědeckého přístupu ke zkoumání neživé přírody spočívá v jeho schopnosti vysvětlovat a předpovídat jevy na základě pozorovatelných a opakovatelných dějů pomocí poznanych zákonů. Slabinou vědy je bohužel neschopnost zkoumat jedinečné, složité a neopakovatelné události jako je např. vznik života. Abychom mohli pochopit reálný složitý svět vytváříme si jednodušší modely, které nám umožňují řešit problémy z našeho zájmového hlediska. Navržený zjednodušující model reality ale vyhovuje pouze za určitých předpokladů, např. systém, který modelujeme je lineární a pak v něm platí princip superpozice. Model chemické evoluce zase předpokládá, že v době vzniku života „nevstoupila do dění žádná nadpřirozená síla“, která by nějakým podstatným způsobem ovlivnila proces a pak zmizela a začneme nejprve s jednodušším kyvadlem, kdy na tenkém závěsu máme zavěšenou pouze kuličku a na desce pod kyvadlem nejsou žádné magnety (je úplně prázdná). Tento zjednodušený model lze za určitých podmínek popsat pomocí matematického kyvadla. Vychýlíme-li kuličku a pak ji pustíme, nastane opakující se děj, kdy kulička kmitá s dobou kmitu T . Doba kyvu $T/2$ matematického kyvadla nezávisí na hmotnosti a rozkmitu, pokud nepřekročí 5° (neboť přibližně platí $\sin \alpha = \alpha$ pro $\alpha < 5$). Dále doba kyvu matematického kyvadla je přímo úměrná druhé odmocnině z délky kyvadla l a nepřímo úměrná druhé odmocnině tíhového zrychlení. Kyvadlo s dobou kyvu jedna sekunda má v naší zeměpisné šířce délku $l = 0,994$ m. Na modelu kyvadla můžeme vysvětlit také první a druhý zákon termodynamiky. Obecně platí, že změna energie ΔE soustavy je rovna práci ΔW vykonané v systému nebo systémem a toku tepla ΔQ do nebo ze soustavy. Pustíme-li kuličku z počáteční polohy, pak podle prvního zákona o zachování energie se změna polohové energie přemění na změnu kinetické energie. Počáteční poloha kuličky je o výšce h výše oproti nejnižšímu bodu C , který se nachází na svislici pod bodem závěsu. V počáteční poloze je nulová kinetická energie, která se směrem k bodu C zvyšuje až v bodě C dosáhne maxima. V tomto bodě je naopak nejnižší polohová energie. V důsledku tření kuličky o vzduch se část energie přemění v teplo, čímž kulička postupně zmenšuje amplitudu kývání až se zastaví v bodě C . Podle druhého zákona termodynamiky uvolněné teplo v důsledku tření zvýšilo entropii okolí kuličky.

Položíme-li na základní desku magnety, přičemž jsou všechny orientované jedním směrem (např. severním pólem nahoru) a místo kuličky zavěsíme magnet orientovaný severním pólem dolů, pak se systém stane silně nelineárním a nebude možné si vytvořit zjednodušující matematicko-fyzikální model, který by se po dostatečně dlouhou dobu choval stejně jako reálný systém magnetického kyvadla. Pustíme-li kyvadlo s magnetem z počátečního bodu nebudeme již schopni předpovědět kde se kulička zastaví, tj. nad kterým atraktorem (malé kroužky na obrázku). Naopak známe-li konečnou polohu nebudeme schopni určit nyní počáteční polohu. Jestliže celý děj nafilmujeme pomocí kamery, tj. zaznamenáme historii, pak se můžeme vrátit do minulosti. Abychom mohli stanovit konečnou polohu ze znalosti počáteční polohy nebo naopak ze znalosti koncové polohy stanovit počáteční, potřebovali bychom nekonečně velkou informaci a tu nikdy mít nebudeme. Např. přesnost počáteční polohy můžeme stanovit pouze s omezenou přesností (chybou). Během pohybu kyvadla nad magnety se tato chyba neustále zvyšuje až získané výsledky jsou zcela bezcenné. Pokud bychom kyvadlo spustili opět ze „stejného místa“ a pak pohyb kyvadla srovnávali s předchozím záznamem kamery, viděli bychom, že od určitého místa se začnou oba pohyby rozcházet. To je místo, kam lze stanovit predikci (nejvzdálenější místo smysluplné předpovědi) vzhledem nepřesnosti počáteční polohy a nelineární složitosti sledovaného systému. S tímto problémem se setkáváme také u předpovědi počasí. Pomocí počítačů a družic jsme schopni předpovědět počasí na několik dnů dopředu ale ne jaké počasí bude za rok. Podobně se lidé marně snaží o co nejlepší dlouhodobou předpověď akcí na burze.

„Jak vznikl život?“ Protože nikdo nezaznamenával vznik života (jeho historii), proto nelze nikdy zpětně zjistit jak to ve skutečnosti proběhlo. Nikdy nebudeme mít „dostatek“ potřebných informací. Lze pouze odpovědět na otázku jestli život mohl evolucí vzniknout, neboť se asi podaří najít hypotézu nebo i více možných hypotéz (cest) vzniku života. Nikdy ale nebudeme moci říci, která byla ta pravá, tj. jak to skutečně proběhlo. Budeme moci odpovědět na otázku zda život mohl sám vzniknout (např. evolucí). Všechna vysvětlení vzniku života budou vždy pouze spekulativní. Věda tedy nemůže dát jednoznačnou odpověď na vznik života a stejně jednotlivá náboženství nemohou ukázat svého Boha. To je patová situace. Pokud ale víra v některé náboženství člověku pomáhá navodit stav duševní rovnováhy, snižuje stres, pak může mít i pozitivní vliv. Trvalá stresová zátěž snižuje účinnost imunitního systému a tak paraziti (viry, bakterie apod.), kteří jsou vždy připraveni zaútočit, mají větší šanci, že uspějí a ve smrtelném boji o potravu (energii) zvítězí. Je vždy těžší odpovídat na otázku „Co něco je“ (např. „Co je to pravda, odvaha, hmota, informace, stroj, život atd.?“), než když se ptáme tak, že odpověď obsahuje např. srovnání nebo změnu (např. „Kdy je informace větší?, „Kdo byl odvážnější?“). Nejhorší jsou špatně postavené otázky, na které nelze odpovědět (např. „Co je smyslem života“). Říci, že jsme tady abychom akumulovali sluneční energii (z pohledu Slunce) asi nikoho neuspokojí. Slunci je úplně jedno co si my o tom myslíme. Protože evoluční proces nějakým způsobem nasměrovává naše chování prostřednictvím instinktů (pudů), je vhodné přemýšlet jak život prožít „šťasněji“, užít si co nejvíce slasti a co nejméně bolesti. Jak bude uvedeno dále „ono“ to není tak jednoduché.

6.6.1. Řád, složitost a informace.

Informační obsah struktury představuje minimální počet bitů potřebných k jejímu popisu, ať už je touto strukturou kámen, počítač nebo mozek. Čím je struktura složitější, tím delší popis, tj. více bitů potřebujeme k jejímu ekvivaletnímu popisu (přepisu do jedniček a nul). Je nutno rozlišovat rozdíl mezi řádem (uspořádaností) a složitostí systému. Charakteristickým rysem uspořádané struktury je pravidelné opakování jejich podstruktur (částí). Uspořádané struktury mají malý informační obsah, neboť k jejich popisu stačí několik faktů, jejichž

binární popis (přepis) je krátký. Když např. chcete si nechat vyrobit krystal, pak stačí chemikovi specifikovat látku, ze které chcete mít krystal a způsob jakým chcete poskládat molekuly dohromady (typ krystalové struktury). Proces opakování základní krystalové struktury (mřížky) se pak nechá opakovat tak dlouho, dokud nevznikne krystal. Informaci o základní struktuře stačí zadat pouze jednou, protože krystal má pravidelně se opakující vzorec. Analogicky aby tiskárna popsala plnou stránku pozdravy „Nazdar Pavle“, stačí algoritmus se dvěma příkazy: (1) vytiskni „Nazdar Pavle“ a (2) opakuj příkaz (1) dokud není celá stránka popsána. Algoritmus může obsahovat i opakující se vzorec: (1) nastav $n = 1$, (2) zvyš n o jedničku a pak vytiskni $2n + 1$, (3) opakuj bod (2) dokud $n < 100$. Pokud je vzorec složitější, nemusí být jednoduchost struktury na první pohled patrná (např. zdánlivě složitá struktura fraktálů vytvořená opakovanými transformacemi).

Podobně nahodilá struktura, která nemá žádný řád, neboť je neperiodická a nespecifikovaná, obsahuje jen málo informací. Její popis je pak relativně krátký, tj. stačí poměrně málo bitů v ekvivalentním binárním přepisu daného popisu. Takovou strukturu může mít žulový kámen, signál bílého šumu, papír popsáný řadou nahodilých písmen. Algoritmus pak může obsahovat také pouze dva příkazy: (1) vyber náhodně jakékoliv písmeno od A do Z a vytiskni ho, (2) opakuj příkaz (1) dokud není celá stránka popsána. Takto můžeme vytvořit libovolně dlouhý nahodilý sled písmen (text).

Naopak neperiodické a nenahodilé struktury označujeme jako „složitě“, např. struktura DNA popisující živou strukturu - organizmus. Čím je struktura složitější, tím je i její popis delší. Popis složité struktury také obsahuje více informace, která je nepřímo úměrná pravděpodobnosti, že bychom popis dané struktury mohli uhodnout a provést tak predikci jejího pokračování. Kdyby jste chtěli vytisknout nějakou knihu, pak příkazy pro Vaše PC budou skoro stejně dlouhé jako vlastní text knihy. Kratší zápis by mohl být zapsán např. těsnopisem, kompresním algoritmem, neboť psaný text obsahuje jistou redundanci aby bylo možné chybný text opravit. Pokud by text neobsahoval žádnou redundanci, pak v případě chyby by byl neopravitelný (např. překlep číslice v čísle vytvoří jiné číslo).

Složité adaptivní systémy sdílí určité klíčové vlastnosti (nelinearitu, složitou směs pozitivních a negativních zpětných vazeb, emergenci, kolektivní chování, spontánní organizaci, hierarchickou strukturu a pod.). Každý hierarchický (vícestupňový, víceúrovňový) systém je složen z elementů jednodušších (podsystemů). Tyto podsystemy mohou být ovšem tvořeny z dalších podsystemů nižšího řádu, tyto z dalších podsystemů ještě nižšího řádu atd. Jednotlivé organizační stupně nazýváme též hladiny (úrovně) systému. Vztahy uvnitř hierarchického systému můžeme rozdělit na horizontální a vertikální. Horizontální vztahy jsou vztahy mezi podsystemy ležícími na stejné organizační úrovni, vztahy vertikální pak vztahy mezi podsystemy na různých organizačních úrovních. Definování různého charakteru vztahů na různých organizačních hladinách má zásadní význam.

Se zvyšující se vertikální organizovaností se objevují (emergují) nové vztahy, které na nižších organizačních hladinách neexistovaly, tzn. objevují se i kvalitativně nové vlastnosti, které nemají podsystemy. Pro různé organizační úrovně je nutné použít metody, které jsou dané hladině jevů adekvátní. Hierarchické uspořádání umožňuje uplatnění tzv. stavebnicového principu, kdy z stejných prvků můžeme tím, že je dáme do různých vztahů, vytvořit systémy kvalitativně odlišné. Význam stavebnicového principu je hlavně ekonomický. Např. buňce stačí pouze dvacet metabolických drah pro syntézu dvaceti hlavních aminokyselin k tomu, aby vytvořila prakticky neomezené množství bílkovin. Totéž platí pro nukleotidy, které kódují celou rozsáhlou genovou paměť. Všechny organismy mají společné základní vlastnosti, které je charakterizují jako živé soustavy. Různé organismy se navzájem liší především složitostí jejich organizace (organismy nebuněčné – viry, organismy jednobuněčné – mikroorganismy a mnohobuněčné organismy).

Tvorba složitě organizovaných hierarchických systémů probíhá stupňovitě, postupným vytvářením relativně stabilních, stále vyšších celků. Doba potřebná k vytvoření konečného složitěho celku se zkrátí nebo je postupná výstavba dokonce podmínkou pro jeho vytvoření v reálném čase. Při postupné výstavbě je dána možnost eliminovat chyby, které náhodně na úrovni nějakého podsystemu vznikají. Pravděpodobnost, že vznikne systém o správné konečné struktuře, se tak podstatně zvyšuje oproti „jednorázové“ syntéze systému.

Zvířata se učí mnohem méně než člověk, neboť spoléhají více na instinkty. Cílem instinktů je předpřipravenost, tj. genově určené způsoby reagování. Reakce jedince je pak dána kombinací instinktivního a naučeného chování. Žádný z našich instinktů nás nemusí nevyhnutelně ovládnout. Žádný morální systém nikdy nevycházela z předpokladu, že jsme andělé a dobrovolně uposlechneme vše co nám ukládá. Biblické „Nepožádáš manželky bližního svého, nezabiješ atd.“ není něžné upomenutí, ale příkaz abychom drželi na uzdě jisté instinkty, které by nás mohly ovládnout. A neudržíme-li je na uzdě hrozí nám trest. Kdyby učení nahradilo všechny naše instinkty, než aby je doplňovalo, pak bychom se půl života učili věcem, na které automaticky reaguje každá opice. Baldwinovým efektem se některé účelné reakce mohou změnit na instinkty, čímž ušetří organismu spoustu času s učením a umožní okamžitou reakci.

V exponenciálně narůstající lidské populaci se stále více začíná projevovat „tragédie společných statků“, která vyplývá ze vztahů ke společnému prostředí. Např. vesničan, který pase příliš mnoho krav na společném pozemku (nebo rybář, který vyloví příliš mnoho ryb), shrábne celý zisk ze svých krav (nebo ryb). Zisk jde do jeho vlastní kapsy, zatímco o ztráty se dělí s ostatními. Je to jednosměrná cesta vedoucí k bohatství jednotlivce a chudobě celku (např. vesnice), z níž není návratu. V důsledku tohoto jevu jsou likvidovány deštné pralesy, přestože je nám známo jaké to bude mít následky v budoucnosti. Bohužel tento proces je ekologicky nestabilní a zatím neexistuje žádná účinná zpětná vazba, která by jej zastavila. Opět si můžeme představit podobnou situaci na modelu magnetického kyvadla. Pokud vychylujeme kyvadlo z klidového stavu, který se nachází nad jedním z atraktorů (viz obr. 1b), pak ještě do určité vzdálenosti je kyvadlo schopné se vrátit do původního stabilního stavu. Překročí-li výchylka kyvadla mez stability, která se nachází mezi dvěma sousedními atraktory (stabilními body), dojde k rychlému přeskočení směrem k sousednímu atraktoru. Současné zásahy lidstva do ekosystému jej vychylují směrem k mezi stability (např. kácení a vypalování deštných pralesů, znečištění životního prostředí atd.) a my bohužel nevíme jak daleko jsme od této hranice. Pokud ji přeskochíme dojde k rychlému lavinovitému ději, který skokem změní klimatické podmínky na Zemi a lidstvo může čekat stejný osud jako dinosaury.

Když sledujeme buňky v organismu, tj. v systému, který je otevřeným systémem, pak tok hmoty a energie přichází z vnějšího světa. Volná energie E může vytvořit P různých organismů (druhů) s N_i kopiemi, které nesou DNA informaci I_i , kde Q_{in_i} je metabolické teplo uvnitř organismu uvolňované jeho aktivitami, Q_{out} je metabolické teplo, které je uvolněno organismem do prostředí. T_i je teplota organismu, m_i je jeho hmotnost, V_i je objem organismu, W je energie biologického odpadu organismů, která je dále ještě využitelná jinými jednoduššími organismy, c_1 , c_2 jsou konstanty:

$$E = E_{structure} + E_{heat} = \sum_{i=1}^P (c_1 N_i V_i o_i + Q_{in_i}) + W + Q_{out}, \text{ kde} \\ Q_{in_i} = c_2 N_i m_i T_i \quad (6.1)$$

o_i je míra energetického uspořádání (definovaná pomocí energetické hustoty $o_i = E_{structure_i}/V_i$). Na Zemi vznikla velice složitá biosféra s potravním řetězcem, který musí vyhovovat omezeným potravním zdrojům definovaných pomocí (6.1). Nárůst energetické potřeby ΔE je pokryt sluneční energií a termální energií Země. Daleko od rovnovážného stavu

se mohou objevit různé typy samoorganizujících se struktur. Cílem evoluce (fitness F_e) je maximalizovat akumulaci energie v živých systémech ve složité hierarchické struktuře popsané v [35]:

$$F_e = \max_{\text{through_evolution}} \left\{ c_1 \cdot \sum_{i=1}^P N_i V_i O_i \right\} \quad (6.2)$$

Živé organismy jsou velice složité z termodynamického hlediska. Některé reakce se nacházejí blízko rovnovážného stavu, zatímco jiné nikoliv. Otevřené systémy se mohou vyvíjet do stále složitějších forem komplexity. Molekulární biologie ukazuje, že ne všechno je živé stejným způsobem. Některé procesy dosahují rovnováhy, jiné jsou pomocí regulačních enzymů tlačeny daleko od rovnováhy [35]. Tok energie nebo hmoty soustavou ji může udržet daleko od rovnováhy, což vede ke zvýšení uspořádanosti. Rostliny slouží celému biologickému světu svou schopností zachycovat a uchovávat energii slunečního záření.

Příroda se dala při řešení rovnice (6.2) dvěma cestami, tj. jak maximalizovat člen $N_i V_i O_i$. Protože hustota informace je na jednotku objemu buňky srovnatelná u různých živočichů, mohou být evolucí preferovány malé organismy s velkým počtem kopií nebo složité velkoobjemové organismy s menším počtem kopií. Člověk, který si myslí, že je posledním článkem evolučního procesu ale neustále zápasí s parazity (jednoduššími a maloobjemovými organismy). Těžko říci, která evoluční větev je lepší. Kdyby došlo k velké klimatické změně (skokem) mají asi jednodušší organismy větší šanci na přežití.

Univerzální termodynamická rovnice, která musí být splněna při každé chemické reakci podle [35]:

$$\begin{array}{ccccccc} \Delta G & = & \Delta H & - & T\Delta S_t & - & T\Delta S_k \\ \text{Gibsova} & & \text{chemická práce} & & \text{tepelná entropická} & & \text{konfigurační entropická} \\ \text{volná energie} & & \text{(entalpie)} & & \text{práce} & & \text{práce} \end{array} \quad (6.3)$$

kde $\Delta H = \Delta E + p\Delta V$. Změna entalpie ΔH je zejména výsledkem změn celkové vazebné energie ΔE , protože člen $p\Delta V$ (součin tlaku a změny objemu) je zanedbatelný. Změna entropie ΔS je definována poměrem tepla ΔQ , které do soustavy vstupuje nebo vystupuje a absolutní teploty T : (6.4)

$$\Delta S \geq \frac{\Delta Q}{T}$$

Tepelná entropie S_t je spojena s distribucí energie v soustavě, zatímco konfigurační entropie S_k se týká uspořádání hmoty v soustavě. Je-li počet možných distribucí energie Ω_t a uspořádání hmoty Ω_k , pak entropie soustavy $S = k \ln \Omega_t \Omega_k = S_t + S_k$. Entropie soustavy je mírou pravděpodobnosti daného uspořádání hmoty a energie v tomto systému. Chceme-li přeměnit náhodný polymer na informační molekulu DNA, můžeme zjistit vzrůst informačního obsahu I jako rozdíl entropie náhodného polymeru a informační molekuly:

$$I = k \ln \Omega_{kn} - k \ln \Omega_{ki} \quad (6.5)$$

kde k je Boltzmanova konstanta. Převedení toku energie systémem na chemickou a tepelnou energii je mnohem snazší než převedení na konfigurační entropickou práci (spojenou s nárůstem informace). Sama informace je nehmotná a potřebuje nosič, kterým je buď hmota nebo energie. S tím souvisí i diskuse na téma tělo-duše. Protože duše se „chápe“ intuitivně jako něco nehmotného pak by to „mohla“ být informace (životní zkušenost) a tělo něco jako „paměť“ (mozek tvořený neurony).

Chci-li přeměnit hromadu stavebního materiálu na dům, pak potřebuji kromě práce (toky energie) také zkušenost (informaci) o postupu jak postavit dům. Určitě nepostačí energie dynamitu nebo uragánu, která by náhodně vytvořila složitou strukturu moderního domu.

6.6.3. Samoorganizace a adaptace složitých systémů

Pro složité adaptivní systémy je typické, že obsahují nelinearitu, složitou směs pozitivních a negativních zpětných vazeb, emergenci, kolektivní chování, spontánní organizaci apod. Každý z těchto systémů je síť skládající se z mnoha jedinců (agentů) pracujících paralelně. Interakcí jednotlivých částí dochází ke vzniku emergentních vlastností, které vzniknou vzájemným působením více agentů mezi sebou a prostředím. Tento typ kolektivních vlastností se nemůže objevit u jednoho nezávislého agenta. Změny chování agenta indukují změny chování jeho sousedů, a tak může dojít k lavinovým adaptivním změnám. Adaptivní procesy dostávají systémy na „hranu“ chaosu, kde řád (uspořádanost) je v rovnováze s chaosem a současně účelová funkce (fitness) dosahuje optima.

Přírodní výběr není v rozporu se samo-organizací, neboť je silou, která neustále tlačí emergentní a samo-organizující se systémy směrem k hraně chaosu (the edge of chaos). Živé systémy se pohybují právě blízko této přechodové fáze na hranici chaosu, což by mohlo vysvětlit v některých případech zázračnou rychlost evoluce. S největší pravděpodobností se obě síly (mutace a výběr) doplňují a umožňují rychlejší paralelní postup evoluce. U dynamických systémů můžeme najít přechodové fáze uspořádanosti, složitosti (komplexnosti) a chaosu.

Základní tendencí všech živých organismů je reprodukce (zachování života jedince a druhu). Pro naplnění této tendence jsou tři základní schopnosti organismu a jeho vztahu k životnímu prostředí: 1. schopnost výměny látek a energie (metabolismus), 2. pohybové vlastnosti, 3. schopnost řízení chování na základě příjmu a zpracování informací z vnitřního a vnějšího prostředí.

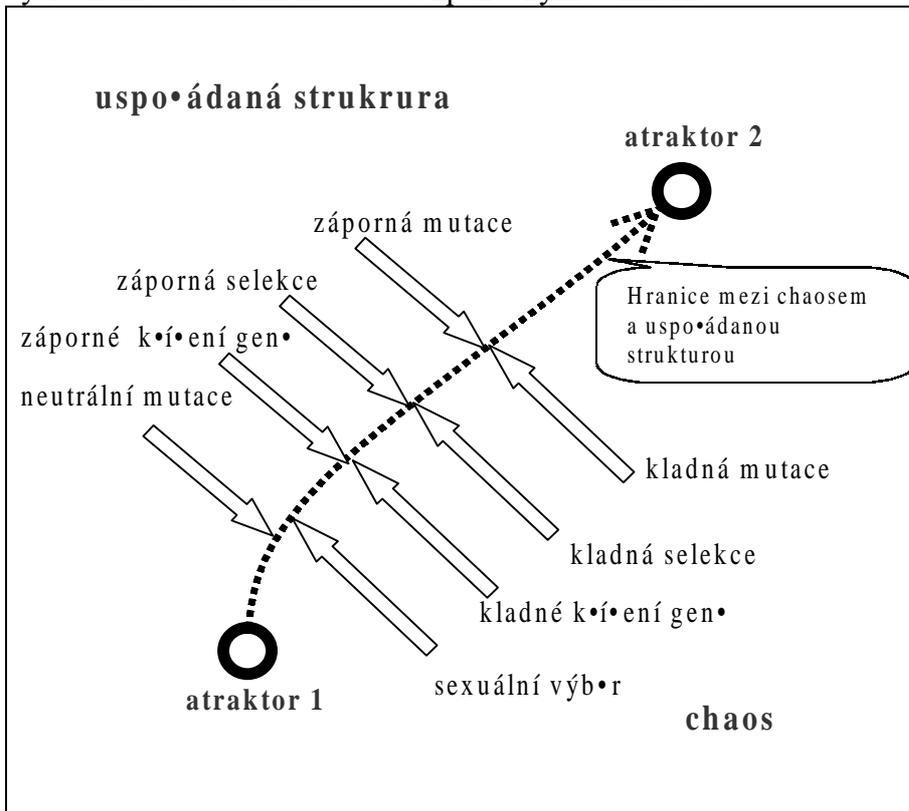
Nejnámějším evolučním principem je darwinismus, podle něhož se živočišné druhy pozvolna vyvíjely z předcházejících forem. Dnes mluvíme ještě o paralelnosti darwinovských procesů [10] (vznik skokových změn umožňujících vysvětlit i vznik oka). Tak se utvářely z hlediska adaptace nejen vhodné tělesné orgány, ale i psychika. Některé organismy se rozmnožují nepohlavně (např. nezmar).

Pohlavní rozmnožování je „evolučním vynálezem“ vyšších organismů, který zajišťuje vyšší variabilitu a tím i vyšší adaptaci na prostředí (včetně parazitů). Některé organismy žijící ve stabilním prostředí se rozmnožují nepohlavně, ale objeví-li se v životním prostředí větší změny, vyvstane generace s pohlavním rozmnožováním, u které potomci mají novou kombinaci genů. Vývoj organismů k větší dokonalosti předpokládá tedy existenci pohlavního pudu. Příroda nutí rovněž člověka k rozmnožování a dává mu za to slast. Člověk však dokázal přírodu přelstít, neboť tuto slast dokáže od rozmnožování oddělit pro dosažení blaženosti (bez rodičovských povinností).

Způsobilost organismů využívat zkušenost jim umožňuje modifikovat nebo měnit vrozené způsoby chování, eventuálně získávat nové formy chování, v nichž se jen relativně málo uplatňují vrozené, geneticky kódované, způsoby chování. Zkušenost může být individuální nebo druhová. První souvisí s individuálním procesem učení, druhá s vrozenými způsoby chování, instinkty. V instinktech se projevuje účelná organizace chování a to nejen vzhledem k aktuální situaci (např. vyhnout se nebezpečí) ale i vzhledem k budoucnosti (např. vytváření zásob pro larvy, které se ještě nevylíhly).

6.6.4 Nárůst uspořádanosti systémů

Nejrychleji probíhá proces evoluce nachází-li se na hranici mezi chaosem a uspořádanou oblastí (on the edge of chaos, viz obr.6.4). Na tuto hranici evoluční proces z oblasti chaosu tlačí kladná selekce (Darwinovský přírodní výběr), kladná mutace (zlepšující úspěšnost organismu), křížení genů s kladným účinkem, sexuální výběr. Naopak z uspořádané a těžko proměnné struktury na hranici s chaosem tlačí záporná mutace (mutace se zhoršující se kvalitou organismu), záporná selekce (např. u imunitního systému), křížení genů s negativním výsledkem a neutrální mutace se zpožděným účinkem.



Obr.6.4 Proces evoluce na hraně mezi chaosem a uspořádanou strukturou

U nelineárních dynamických systémů nejmenší neznalost počátečních podmínek se projeví neúprosným nárůstem odlišného chování od předpokládaného, takže predikce chování těchto systémů je pak bezcenná. Složitě nelineární systémy mají svoji historii, ale z daného aktuálního okamžiku nelze udělat ani dlouhodobou předpověď chování systému ani vypočítat stav systému v minulosti. Lze udělat pouze možný odhad, který se s určitou pravděpodobností shoduje s realitou. Na základě této úvahy nikdy nebude možné určit jak přesně vznikl život, pouze bude možné nalézt možnou cestu, o které nikdy nebudeme moci říci zda-li je správná.

U složitých systému se často jedná o „sít“ s velkým počtem „agentů“ pracujících paralelně. Např. v mozku agentem je nervová buňka. Každý agent je součástí prostředí, na které působí ale které jej také ovlivňuje. Jedná se o interakci s ostatními agenty, tj. neustálé působení a reagování na to co ostatní agenti dělají. Dojde často ke vzniku emergentních vlastností (anomálií), interakcí mnoha částí, věcí které skupina agentů může dělat kolektivně, něco co jednotlivý agent dělat nemůže. Např. imunitní systém je řízen lokální interakcí mezi buňkami a antigeny (protilátkami). Imunitní systém nemá centrální řízení. Podobné chování lze vysledovat v rozvoji Internetu. Paralelní evoluce agentů může vysvětlit vznik oka. Darwinova teorie postupné evoluce není nesprávná, je pouze neúplná. aby mohla vysvětlit

některé jevy evoluce. Evoluce pracuje paralelním způsobem. Evoluce probíhá postupnou změnou v paralelně se vyvíjejících částech, které v důsledku vzájemného ovlivňování mohou přejít v důsledku vzájemné rezonance (v důsledku kladných zpětných vazeb) lavinovým skokem z jednoho stabilního stavu do druhého (traktoru). Většinou každá část paralelní evoluce má Darwinovský postupný vývoj, ale v důsledku kladných zpětných vazeb komplexní struktura se může změnit lavinovitým skokem. Proto paleontologové nemohou najít některé chybějící články postupné a pozvolné Darwinovské evoluce, tj. chybějící články řetězce ve vývoji druhů. Vývoj mobilního telefonu proběhl podobným způsobem. Na začátku to byl paralelní nezávislý vývoj telefonu a rádia, které se v určitém okamžiku spojily lavinovým skokem, a tak vznikl mobilní telefon.

6.7 Gramatická evoluce pro identifikaci a řízení systémů

Gramatická evoluce (GE) [37-40] může být chápána jako typ genetického programování (GP) založeného na gramatice. Genetické programování navržené Kozou bylo původně programováno v jazyce LISP. Pomocí gramatické evoluce můžeme vytvořit programy v libovolném jazyce, pokud použijeme Backus-Naurovu formu (BNF). V BNF autoři Backus a Naur definovali programovací jazyk ALGOL. Gramatiky BNF se skládají z terminálů, což jsou objekty, které se mohou vyskytovat v daném jazyce, např. +, -, sin, log atd. a neterminálů. Neterminály mohou být nahrazeny jedním nebo více terminály a neterminály. Neterminální symbol je každý symbol, který může být přepsán na jiný řetězec symbolů. Naopak terminální symbol nemůže být již přepsán. Hlavní výhodou GE oproti GP je dána možností generování víceřádkových funkcí v libovolném programovacím jazyce. Programy v GE nejsou zapsány přímo ve stromové struktuře jako je tomu u GP, ale pomocí lineárního genomu, což může být např. posloupnost celých čísel. Převod z genotypu do fenotypu se provádí pomocí operací modulo n , kde n je určeno maximálním smysluplným výběrem, např. daným počtem funkcí. Gramatikou budeme nazývat čtveřici $G = \{N, T, P, S\}$, kde

N je konečná množina neterminálních symbolů,

T je konečná množina terminálních symbolů, přičemž $N \cap T = \emptyset$,

S je počáteční symbol, $S \in N$,

P je množina přepisovacích pravidel.

Chceme-li např. identifikovat jednoduchou funkci $\cos 2x$ v rozsahu $[0, 2\pi]$ pomocí identické goniometrické funkce $1 - 2\sin^2(x)$, můžeme použít následující gramatiku [39]:

$N = \{\text{expr}, \text{op}, \text{pre_op}\}$

$T = \{\text{sin}, \text{cos}, \text{log}, +, -, *, /, X, 1, 0, (,)\}$

$S = \langle \text{expr} \rangle$

a přepisovací pravidla P :

$\langle \text{expr} \rangle ::= \langle \text{expr} \rangle \langle \text{op} \rangle \langle \text{expr} \rangle \quad (0)$

nebo $(\langle \text{expr} \rangle \langle \text{op} \rangle \langle \text{expr} \rangle) \quad (1)$

nebo $\langle \text{pre_op} \rangle (\langle \text{expr} \rangle) \quad (2)$

nebo $\langle \text{var} \rangle \quad (3)$

$\langle \text{op} \rangle ::= + \quad (0)$

nebo $- \quad (1)$

nebo $/ \quad (2)$

nebo $* \quad (3)$

$\langle \text{pre_op} \rangle ::= \text{sin} \quad (0)$

nebo \cos (1)

$\langle \text{var} \rangle ::= x$ (0)

nebo 1.0 (1)

Tento způsob zápisu pravidel se mírně liší od GP. První pravidlo má čtyři možnosti výběru, druhé tři, třetí dvě a čtvrté dvě. Neterminální symboly jsou v lomených závorkách $\langle \rangle$. Začíná-li posloupnost genotypu např.:

220, 240, 220, 203, 101, 53, 202,.....atd.,

pak aplikací prvního pravidla, které má čtyři možnosti, na počáteční symbol $\langle \text{expr} \rangle$ provedeme tak, že číslo výběru použité možnosti dostaneme operací modulo n , kde $n = 4$, neboť výběr začíná již možností (0) a např. 220 modulo 3 = 0. Počáteční symbol S je tedy nahrazen pomocí prvního pravidla, a to variantou (0): $\langle \text{expr} \rangle \langle \text{op} \rangle \langle \text{expr} \rangle$. Nahrazování pak pokračuje aplikací pravidla vždy na neterminální symbol, který nejvíce vlevo, a to tak dlouho dokud nejsou všechny neterminální symboly nahrazeny terminálními symboly. Algoritmus končí např. výrazem:

$1.0 - \sin(x) * \sin(x) - \sin(x) * \sin(x)$.

6.7.1 Paralelní evoluční algoritmy

Paralelní genetické algoritmy (PEA - Parallel Evolutionary Algorithms) jsou výkonné stochastické prohledávací strategie inspirované přírodou, dovolující řešit větší a složitější problémy, přičemž často vedou rychleji k řešení a současně konvergují i k lepším výsledkům. Používají se tři modely PEA: „farmářský“ model (farming model), migrační model a difusní model. Někdy se pro poslední dva typy PEA používá název distribuované genetické algoritmy (DEA). PEA pracuje s nezávislými podmnožinami populace, v nichž probíhá evoluce částečně izolovaně (dále jen podpopulace). Pojem paralelní nebo sekvenční se vztahuje k populačním strukturám, nikoli k hardwaru, na kterém jsou evoluční algoritmy implementovány.

Migraci rozumíme smísení určité populace s jinou populací. Jejím následkem je vnášení (import, tok) cizích alel do genového fondu dané populace. Tím se v něm mění frekvence alel. Migrace může být jednosměrná nebo vzájemná (u sousedících populací), jednorázová, periodická nebo trvalá. Kombinovaným účinkem migrace, selekce a genového posunu může v populaci nastat genetická rovnováha se stálým rozdělením genotypových četností.

Jednotlivé migrační modely se liší strukturou propojení jednotlivých podpopulací. Struktura migračního modelu může být s centralizovaným, hierarchickým (stromovým), kruhovým, kruhovým centralizovaným, maticovým (mřížkovým) a toroidním uspořádáním. Každý hierarchický (vícestupňový, víceúrovňový) systém je složen z elementů jednodušších (pod systémů). Tyto pod systémy mohou být ovšem tvořeny z dalších pod systémů nižšího řádu, tyto z dalších pod systémů ještě nižšího řádu atd. Jednotlivé organizační stupně nazýváme též hladiny (úrovně) systému. Vztahy uvnitř hierarchického systému můžeme rozdělit na horizontální a vertikální. Horizontální vztahy jsou vztahy mezi pod systémy ležícími na stejné organizační úrovni, vztahy vertikální pak vztahy mezi pod systémy na různých organizačních úrovních. Definování různého charakteru vztahů na různých organizačních hladinách má zásadní význam. Se zvyšující se vertikální organizovaností se objevují (emergují) nové vztahy, které na nižších organizačních hladinách neexistovaly, tzn. objevují se i kvalitativně nové vlastnosti, které nemají pod systémy.

6.7.2 Použitá gramatika

Gramatiku používáme stejně jako v původním návrhu BNF [39], kde gramatika je reprezentována jako $\{N,T,P,S\}$, kde N je soubor terminálů, T je soubor neterminálů. P je množina produkčních pravidel, S se je startovací výraz.

$N = \{\text{expr, fnc}\}$

$T = \{\text{sin, cos, +, -, /, *, X, 1, 2, 3, 4, 5, 6, 7, 8, 9}\}$

$S = \langle \text{expr} \rangle$

množina 4 produkčních pravidel:

1. $\langle \text{expr} \rangle := \langle \text{fnc} \rangle \langle \text{expr} \rangle$
 $\quad \langle \text{fnc} \rangle \langle \text{expr} \rangle \langle \text{expr} \rangle$
 $\quad \langle \text{fnc} \rangle \langle \text{num} \rangle \langle \text{expr} \rangle$
 $\quad \langle \text{var} \rangle$
2. $\langle \text{fnc} \rangle := \text{sin}$
 $\quad \text{cos}$
 $\quad +$
 $\quad *$
 $\quad -$
 $\quad \text{U-}$
3. $\langle \text{var} \rangle := \text{X}$
4. $\langle \text{num} \rangle := 0,1,2,3,4,5,6,7,8,9$

Jednotlivá pravidla mají počet možných výběrů:

č.pravidla	počet možností
1	4
2	4
3	1
4	10

Místo symbolů $\langle \text{pre_op} \rangle$ a $\langle \text{op} \rangle$, které jsou používané v původním návrhu používáme jednu společnou množinu pro funkce s aritkou n. Dále byla vypuštěna pravidla obsahující závorky, jsou nahrazené stromovou reprezentací funkce. Byla přidána množina $\langle \text{num} \rangle$ obsahující číselnice a pravidlo $\langle \text{fnc} \rangle \langle \text{num} \rangle \langle \text{expr} \rangle$, které slouží ke generování výrazů, v nichž jeden operand je číslo. Pravidlo $\langle \text{fnc} \rangle \langle \text{num} \rangle \langle \text{expr} \rangle$ je odvozené od pravidla $\langle \text{fnc} \rangle \langle \text{expr} \rangle \langle \text{expr} \rangle$, generuje však jednodušší výrazy, kde jeden argument funkce je číslo např. $+(4,x)$, což je ekvivalentní zápisu $(4 + x)$. Stejného efektu je možné dosáhnout, pokud se jeden ze členů pravidla $\langle \text{fnc} \rangle \langle \text{expr} \rangle \langle \text{expr} \rangle$ rozbálí na $\langle \text{var} \rangle$ a poté na číslo, které by bylo v sadě proměnných uloženo. Důvodem pro zavedení pravidla je zjednodušení generování jednoduchých (jednociferných) čísel a umožnění generování složitějších čísel.

Pokud bude generování funkcí probíhat bez omezení, tak je prohledávaný prostor nekonečně veliký a současně i počet řešení je nekonečný. Např. hledání funkce $\cos(2x)$, může mít řešení $\cos(x+x)$; $\cos(x+x+1-1)$; $\cos(x+x+x-x)$; $\cos(x+x+0+0+0\dots)$. Proto je nutné omezit velikost funkce. Dalším omezením je, že každý neterminál i terminál má jako vlastnost počet možných použití (počet výskytů v těle jedince). Pro omezení velikost funkce jsou významné pouze prvky sady $\langle \text{expr} \rangle$, tedy produkční pravidla. Ostatní objekty se mohou nastavit pokud do systému chceme vnést další znalosti o očekávaném výsledku. Všechny sady $\langle \text{expr} \rangle$, $\langle \text{fnc} \rangle$, $\langle \text{var} \rangle$, $\langle \text{num} \rangle$ jsou implementované jako virtuální seznamy. Po každém použití prvku sady se sníží zbývající počet možných použití. V okamžiku, kdy je tento počet roven 0 je prvek

odebrán ze sady. To znamená, že dojde ke snížení počtu pravidel. Také to znamená, že hodnota genu může mít jiný význam v různé úrovni vytváření těla jedince.

Např.

pravidlo	zbývající počet	celkový počet možností
A	0	2
B	3	5
C	3	6
D	3	3

před omezením:

$$8 \bmod 4 = 0 \Rightarrow A$$

$$8 \bmod 3 = 1 \Rightarrow C$$

po omezení:

$$9 \bmod 4 = 1 \Rightarrow B$$

$$9 \bmod 3 = 0 \Rightarrow B$$

Tyto změny jsou však deterministické a nevnašejí do systému chaos. Přesto je vhodnější seznam pravidel seřazený sestupně podle počtu použití.

pravidlo	zbývající počet	celkový počet možností
C	3	6
B	3	5
D	3	3
A	0	2

před omezením:

$$8 \bmod 4 = 0 \Rightarrow A$$

$$8 \bmod 3 = 1 \Rightarrow B$$

po omezení:

$$9 \bmod 4 = 1 \Rightarrow B$$

$$9 \bmod 3 = 0 \Rightarrow C$$

Tedy stejný výsledek operace modulo kóduje stejné pravidlo. Je sice i nadále možné, že dojde nejprve k vyčerpání pravidla C a pak teprve k vyčerpání ostatních a tím opět ke změně významů operace modulo, nicméně nastává to zřídka.

Implementace funkce s aritou n

Seznam `<fnc>` se od ostatních seznamů liší tím, že je virtuální a dvojrozměrný. První rozměr zde představuje počet operandů fce. Po vybrání počtu operandů vznikne seznam, ze kterého se vybere stejným způsobem jako z ostatních. Objekt `TFnc` je potomkem objektu `TEvalObj` rozšířený o seznam zdrojových objektů `Sources: TList`.

Generování závorek ve funkcích

Je vyřešeno pomocí stromové reprezentace funkce. Pravidla se závorkami byla odstraněna a také terminální symboly „(“ a „)“ byly odstraněny ze sady terminálů. Závorky se do textového výpisu funkce vkládají až při vlastním výpisu.

6.7.3 Paralelní gramatická evoluce

Paralelní gramatická evoluce PGE vychází z gramatického evolučního algoritmu popsaného v [37]. Algoritmus je rozšířen o paralelní populační systém, který rozlišuje pohlaví. Každá podpopulace s rozdílným pohlavím používá jiný typ selekce a mutace. Dále obsahuje zpětnou vazbu fenotypu na genotyp.

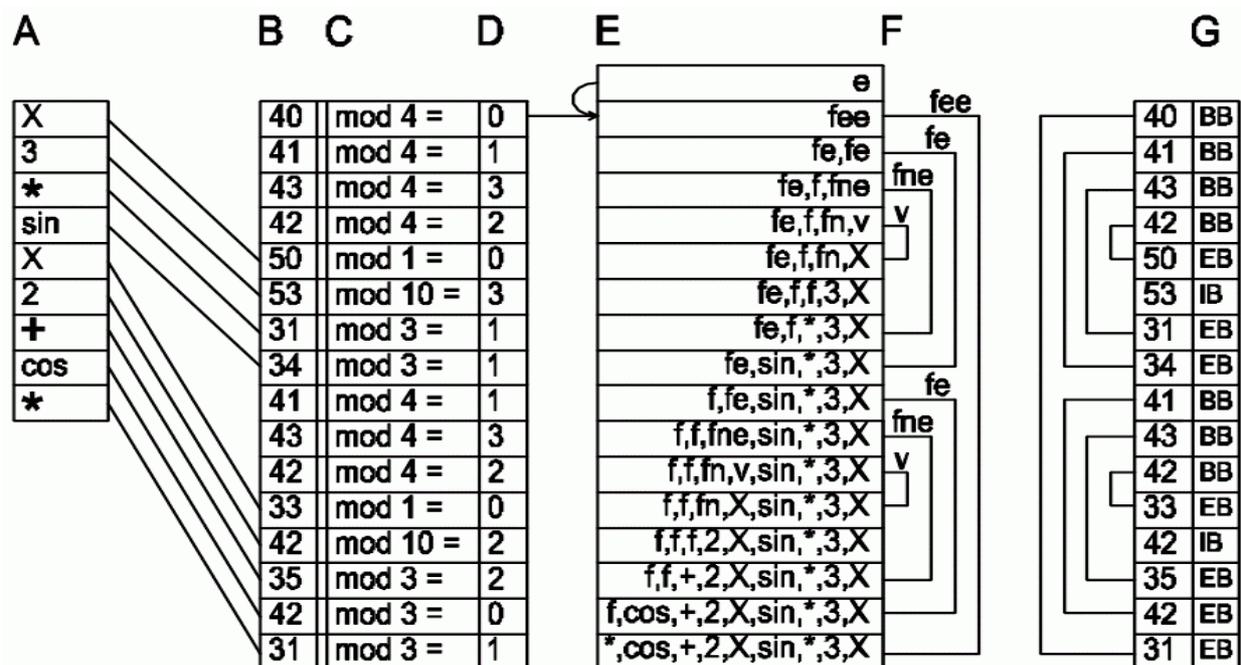
Gramatická evoluce

Chromozom představuje řetězec celých nezáporných čísel, v počáteční populaci náhodně vygenerovaných. Hodnoty genů slouží k rozhodování, který prvek (terminál/neterminál) vybrat při generování těla jedince. První aplikované pravidlo má sadu čtyř možností, proto při výběru pravidla je vybraná možnost určena: hodnota_genu mod 4.

Při výběru proměnné má sada proměnných pouze jeden prvek, výsledek mod 1 je vždy 0, vybere se tedy vždy první prvek (proměnná X). Gen se přečte vždy, i pokud není potřeba udělat žádné rozhodnutí (vybírání se z jednoprvkového seznamu). Toto vnáší do chromozomu jedince redundanci, kdy některé hodnoty genů mohou být libovolné.

Na obr.6.5 je schéma překladu chromozomu jedince na tělo funkce. Tělo jedince je znázorněno jako lineární řetězec, ve skutečnosti je však uloženo v jednosměrném stromu (podřizovaný prvek nemá vazbu na nadřizovaný). Jednotlivé sloupce obrázku 6.5 mají následující význam:

- A. Objekty hotového jedince (výstup překladu),
- B. Geny použité části chromozómu,
- C. Operace modulo: zbytek po celočíselném dělení; hodnota dělitele je daná počtem prvků v seznamu,
- D. Výsledek: zbytek po celočíselném dělení označuje vybraný terminál/pravidlo,
- E. Stav těla jedince po zpracování genu na daném řádku.

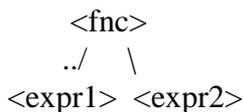


Obr. 6.5 Vztah mezi genotypem (sloupec B) a fenotypem (sloupec A).

Protože do operace modulo vstupují dva operandy, je výsledek zpracování každého genu daný jednak hodnotou genu a současně kontextem genu. Kontext genu je počet možností mezi kterými gen rozhoduje a ten se řídí tím pro co bude gen použitý. Např. gen s hodnotou 42 dává pokaždé jiný výsledek operace modulo v závislosti na tom, jaký je dělitel, tedy pro který seznam je gen použit. Naopak terminál X lze zakódovat více způsoby, stačí pokud vyjde stejný zbytek po celočíselném dělení. V příkladu na obrázku tomu tak bude vždy, protože dělitel je 1 (seznam proměnných je jednoprvkový). Gen, který kóduje terminál X je tedy v daném kontextu redundantní. Pokud při překladu chromozomu dojdou geny, pokračuje se čtením od začátku chromozomu.

Zpracování gramatiky

Zpracování produkčních pravidel probíhá v opačném pořadí, odpředu dozadu. Např. pravidlo $\langle \text{fnc} \rangle \langle \text{expr1} \rangle \langle \text{expr2} \rangle$ se zpracovává jako $\langle \text{expr2} \rangle \langle \text{expr1} \rangle \langle \text{fnc} \rangle$. Zásadní rozdíl mezi neterminály $\langle \text{fnc} \rangle$ a $\langle \text{expr} \rangle$ spočívá v tom, že symbol $\langle \text{fnc} \rangle$ se rozbalí na právě jeden terminální symbol. Naproti tomu neterminál $\langle \text{expr} \rangle$ může obecně představovat libovolný počet členů funkce na různých úrovních stromu výsledného fenotypu. Je-li fenotyp realizovaný pomocí stromu objektů, pak objekt, který vznikne překladem neterminálu $\langle \text{fnc} \rangle$ je zodpovědný za zpracování částí fenotypu, které vzniknou zpracováním $\langle \text{expr1} \rangle$ a $\langle \text{expr2} \rangle$. Pravidlo lze tedy znázornit také jako strom



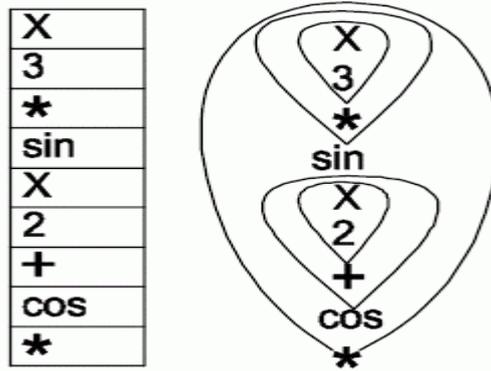
Pro výběr pravidla (výběr typu stromu) je potřeba právě jeden gen, pro jeho zpracování je potřeba n -genů a pro výběr terminálního symbolu funkce je potřeba opět jeden gen. Pozn.: při zpracování pravidla v pořadí $\langle \text{fnc} \rangle \langle \text{expr1} \rangle \langle \text{expr2} \rangle$ je kořen zpracováván jako druhý a poslední zpracováván výraz je jeden z listů podstromu.

Pozn: konstrukce algoritmu umožňuje velmi jednoduché přidání libovolné fce. Např. přidání fce tří proměnných vyžaduje pouze přidání nové funkce do množiny funkcí, a přidání pravidla $\langle \text{expr} \rangle \langle \text{expr} \rangle \langle \text{expr} \rangle \langle \text{fnc} \rangle$ nebo $\langle \text{num} \rangle \langle \text{num} \rangle \langle \text{num} \rangle \langle \text{num} \rangle$ nebo jejich kombinací. Výběr funkcí z množiny je implementován pomocí virtuálního dvojrozměrného pole, tzn., že všechny funkce se vkládají do jednoho seznamu, ale jejich výběr probíhá tak, jakoby byly oddělené seznamy funkcí stejného počtu proměnných.

Při klasickém zpracování v pořadí $\langle \text{fnc} \rangle \langle \text{expr} \rangle \langle \text{expr} \rangle$ popsaném v [39] nelze jednoduše najít stromovou strukturu z genotypu, protože části $\langle \text{expr} \rangle \langle \text{expr} \rangle$ spotřebovávají předem neznámý počet genů a poslední zpracováván neterminál je (z hlediska struktury) nevýznamný list podstromu. Navržený způsob kódování stromové struktury je zobrazen na obr.6.6.

6.7 Promítání fenotypu do genotypu

Při aplikaci tohoto obráceného systému kódování začíná pak každé zpracování podstromu fenotypu výběrem pravidla a končí kořenem tohoto podstromu (v našem případě vlastní funkce). Z pohledu genotypu je pak gen použitý pro výběr pravidla následovaný n geny s různou interpretací (použitými pro zpracování pravidla), které jsou však následovány genem určujícím terminální symbol $\langle \text{fnc} \rangle$. Tedy gen určující pravidlo je párový s genem určujícím kořen podstromu pravidla. Tyto geny lze při překladu chromozomu na tělo jedince označovat.



Obr.6.6 Opačný způsob kódování stromové struktury

Nejjednodušší značení může vypadat takto (viz obr.6.5 sloupec G):

BB - Begin Block

EB - Inside Block

EB - End Block

Značky EB, BB jsou párové, vymezují v chromozomu úseky, které se mohou vnořovat, nemohou se však křížit (jako závorky). Značka IB párová není, ale je vždy obsažená uvnitř nějakého páru. Nalezení příslušného EB genu k zadanému IB genu lze tedy provést pomocí jednoduchého zásobníku (LIFO).

Část chromozomu vymezená jedním párem BB-EB genů pak kóduje jistý podstrom fenotypu. Takovýto blok chromozomu je zcela samostatný a lze ho vyměnit s jiným blokem. Všechny BB geny (a pouze BB geny) určují strukturu těla jedince. EB a IB geny určují terminály, které se objeví ve výsledném fenotypu. BB geny určují výsledný strom jedince (počet podstromů, větví a listů) jsou tedy strukturální, jejich změna ovlivní výběr pravidla a tedy interpretaci ostatních genů. Změna (např. mutace) BB genu způsobí změnu ve výběru pravidla (výsledků operace modulo) mnoha ostatních genů.

Toto označování bloků zavádí zpětnou vazbu fenotypu na genotyp a přitom nesnižuje obecnost algoritmu. Nezávisí totiž na použitých terminálech ani pravidlech, ale pouze na stromové struktuře. Díky tomuto systému je možné podstatné zvýšení výkonu algoritmu nedestruktivním křížením a mutací.

Křížení

Při použití gramatiky závisí výsledný fenotyp jednak na hodnotě genu a jednak na jeho kontextu. Při křížení v náhodném bodě obvykle dochází ke změně kontextu a tedy i ke změně fenotypu. Křížení je tedy destruktivní, neboť nové části chromozómu kódují jiný fenotyp než v původním jedinci. Pokud se však využije označených bloků v chromozomu křížení není destruktivní.

Křížení probíhá jako výměna částí chromozomů dvou jedinců, kde každá část (blok) začíná BB genem a končí odpovídajícím EB genem. BB a EB geny jsou párové značky, proto k výměně dochází vždy v sudém počtu bodů. Výběr BB genů je náhodný a je z něj vyloučen první gen. První gen je párový s posledním genem a uzavírá tedy celé tělo jedince, výměna takovýchto bloků by znamenala pouze záměnu obou jedinců. Křížit lze dokonce i stejné chromozomy.

Tento způsob křížení pracuje podobně jako přímé křížení podstromů funkcí, nicméně stále se vyměňují pouze části chromozomu, tedy genotyp a fenotyp zůstává oddělený. Po křížení je tedy vzniklý jedinec kombinací podstromů obou rodičů, ale známe jeho genotyp,

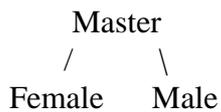
který tuto strukturu může kdykoliv vytvořit. Lze tedy i zjistit pravidla, která jsou pro vytvoření jedince použita. Kdyby se křížily přímo podstromy, byla by na zjištění použitých pravidel potřeba zpětná analýza stromu. Další výhodou tohoto způsobu křížení je, že k vlastnímu křížení není nutné znát fenotyp ani s ním nijak manipulovat (kombinování stromových struktur vs. výměna prvků jednorozměrného pole).

Mutace

Mutaci lze rozdělit na mutaci strukturálních genů. Mutace jednoho strukturálního genu ovlivní ostatní geny, její míra by proto měla být velmi malá (0%-4%). Míra strukturální mutace může být dokonce i nulová, protože nové struktury lze vytvářet progresivním křížením. Rozlišení mutací umožňuje nastavení poměrně vysoké mutace nestrukturálních genů a tedy i rychlejší prohledávání. Přitom nehrozí poškození již nalezené struktury. Pokud jsme schopni určit, že struktura jedince je správná, lze nastavit strukturální mutaci na 0% a mutovat pouze terminální symboly. Např. z funkce $\sin(2 + x) + \cos(3 * x)$ lze pouze pomocí mutace vygenerovat funkci $\cos(5 - x) * \sin(1 * x)$.

6.7.4 Populační model

Systém používá tři populace uspořádané do následující struktury, ve které se rozlišuje pohlaví jedinců:



Tento systém se jeví jako stabilnější, než systém ve kterém jsou všechny 3 populace stejné.

Samičí populace

Při zařazování nového jedince do populace se kontroluje jestli již v populaci neexistuje stejný nebo podobný jedinec. Pokud existuje, pak není nový jedinec do populace zařazen. V samičí populaci se tedy vyskytuje každý genotyp pouze jedenkrát a podobné genotypy také pouze jedenkrát. Takto se v populaci udržuje vysoká míra rozmanitosti, jedinci v populaci tedy vůbec nepodléhají mutaci. Vyřazování jedinců probíhá na základě dvou kritérií, nejprve podle věku (délka pobytu v systému, nikoli v populaci), potom podle fitness, tj. omezení na maximální dovolenou velikost populace. Výběr rodičů probíhá metodou tournamentu.

Samčí populace

Není kontrolováno přidávání nových jedinců, populace proto podléhá mutaci. Míra mutace může být vysoká (až 30%) pokud je mutace strukturálních genů nízká (asi 1%). Pro několik nejlepších jedinců jsou mutace nedestruktivní. Pokud má být jedinec mutován, zařadí se do populace jeho klon. Při stagnaci řešení se mutace lineárně zvětšuje s počtem cyklů, po které se nezlepšilo řešení. Pro výběr rodičů se používají různé principy selekční funkce. Celá část její hodnoty určuje počet výběrů, desetinná část určuje pravděpodobnost dalšího výběru. Např. hodnota 2,03 znamená 2 výběry jisté a třetí. výběr s pravděpodobností 3%. Nejhorší jedinci v populaci mají pravděpodobnost výběru velmi malou (0,02), ale vždy nenulovou.

Master populace

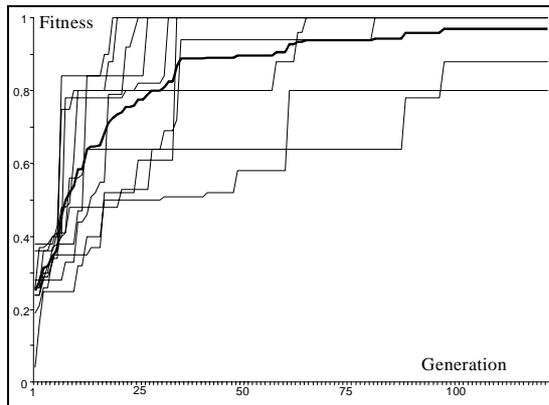
Master populace je populace nadřazená samčí a samičí podpopulaci. Ze samčí a samičí podpopulace dostává v pravidelných intervalech nejlepší řešení. Zároveň provádí vlastní optimalizaci, pro křížení jsou oba rodiče vybíráni pouze z master populace systémem tournamentu. Používá stejný systém mutací jako populace samčí, včetně dynamických mutací.

Vyřazování jedinců však probíhá pouze podle fitness (omezení na maximální povolenou velikost populace). Tato populace tedy slouží zároveň jako archiv nejlepších řešení celého systému.

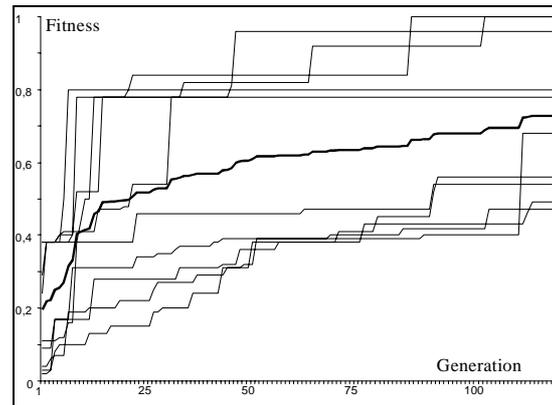
Hodnotící funkce (fitness)

Okolo hledané funkce, definované funkčními hodnotami je toleranční pásmo dané šířky. Fitness jedince je pak poměr počtu vyhovujících bodů a všech kontrolních bodů. Použitý počet kontrolních bodů byl 100. Vyhovující bod je takový, ve kterém hodnota generované funkce leží v tolerančním pásmu okolo hledané funkce. Tento způsob hodnocení vytváří silný selekční tlak, algoritmus proto obvykle velmi rychle nalezne přibližné řešení.

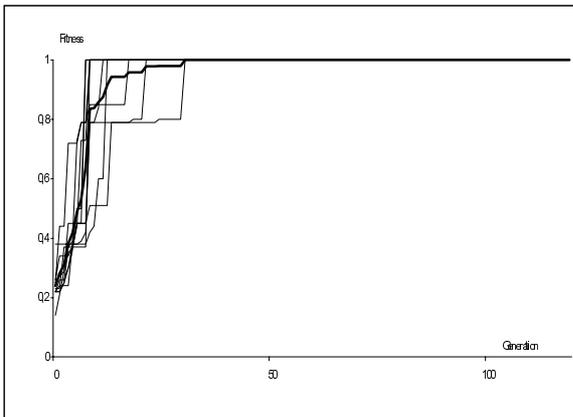
Hledaná funkce (např. $\sin(2 * x) * \cos(2 + x)$).



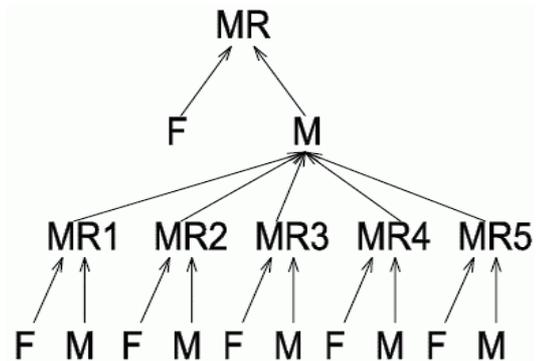
Obr. 6.7 Konvergence PGE používající zpětné zpracování (tučně průměr)



Obr.6.8 Konvergence PGE používající dopředné zpracování (tučně průměr)



Obr. 6.9 Konvergence PGE s 5 PC se zpětným zpracováním(průměr tučně)



Obr. 6.10 Paralelní struktura PGE se 6 počítači PC

Při výpočtu na obr.6.9 byla použita paralelní hierarchická struktura zobrazená na obr.6.10 .

Z obrázků 6.7 až 6.9 je patrné, že nejlepší výsledky optimalizace dává paralelní gramatická evoluce PGE s hierarchickou strukturou a se zpětným výpočtem fenotypu z genotypu (se zpětným zpracováním). Samčí podpopulace M řeší problém konvergence, zatímco samičí podpopulace zvyšují variabilitu systému a tím zlepšují adaptační vlastnosti algoritmu.

Automatické generování programů pomocí paralelní gramatické evoluce PGE umožňuje nalít nejkratší zakódování (popis) daného problému, jevu nebo objektu a tím i jeho informační obsah, neboť délka takto vzniklého algoritmu v bitech určuje i jeho informační obsah, tj. **informaci**, kterou obsahuje. To je poněkud jiný přístup než pomocí logaritmu a pravděpodobností v odstavci 2.2. Pokud je chromozóm s celými čísly na obr.6.5 uzavřen do kruhu (má uzavřenou kruhovou strukturu podobně jako u virů), pak lze každý gen (celé číslo v genotypu na obr. 6.5) použít několikrát, a to pokaždé s jiným významem [39].