


4. prednáška

Úloha učenia v evolúcii a memetika

4.1 Baldwinov efekt a úloha učenia v evolúcii

V r.1896 americký psychológ J. M. Baldwin formuloval hypotézu podľa ktorej, jedinci z populácie *schopní učiť sa majú väčšiu šancu prežitia*, ich fitnes je väčšie ako fitnes jedincov, ktorí túto vlastnosť nemajú. Ak prostredie evolúcie zostáva dlhú dobu nemenné, potom prirodzený výber môže viesť k *emergencii* takých jedincov populácie, ktorí majú túto *schopnosť učiť sa geneticky zafixovanú*, Baldwin nazval tento mechanizmus „*organická selekcia*“. V súčasnosti sa na počesť Baldwina tento jav nazýva *Baldwinov efekt*.

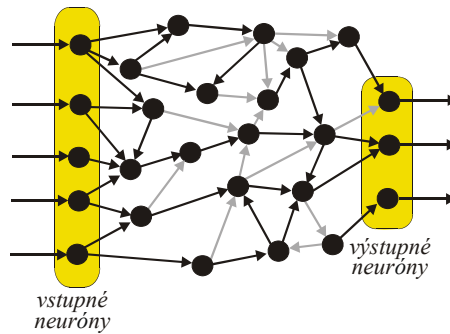
Môžeme teda konštatovať, že pri evolúcii kognitívneho aparátu vystupuje do popredia *aspekt učenia*, t.j. schopnosť jedincov adaptovať si svoj kognitívny orgán tak, aby odrážal v určitom rozsahu zmeny v prostredí alebo nové kognitívne funkcie dôležité pre prežitie a reprodukciu. Význam učenia v darwinovskej evolúcii spočíva v tom, že organizmus s lepším kognitívnym aparátom má väčšiu šancu na prežitie a reprodukciu. Poznamenajme, že základná architektúra a snád' aj počiatkové nastavenie vybraných váhových koeficientov kognitívneho orgánu sa dedične prenášajú na potomkov, avšak neprenášajú sa vedomosti získané rodičmi v priebehu ich života.



Obrázok 4.1. Americký psychológ J. M. Baldwin (1861-1934), ktorý v r. 1896 publikoval prácu „A New Factor in Evolution“ v časopise *The American Naturalist*, v ktorej formuloval úlohu učenia v Darwinovej evolúcii, čo môže vo vybraných prípadoch viesť až ku genetickej fixácii vlastnosti, ktorá bola predmetom učenia.

4.1.1 GA s učením

Moderný pohľad na Baldwinov efekt pochádza od *Hintona a Nowlana* [xx], ktorí pomocou obyčajného genetického algoritmu modelovali tento efekt, pričom chápali učenie ako prehládavanie v určitom okolí aktuálneho stavového bodu parametrov kognitívneho orgánu.



Obrázok 4.2. Znáznornenie jednoduchovej neurónovej siete, hrany znázornené čiernou čiarou majú už fixne nastavený váhový koeficient na binárnu hodnotu 0 alebo 1, ostatne hrany znázornené svetlou čiarou sú len hypotetické spoje, ktoré potenciálne môžu existovať a sú reprezentované symbolom #.

Budeme predpokladať, že chromozóm reprezentuje váhové koeficienty neurónovej siete znázornenej na obrázku 4.2. Niektoré váhové koeficienty w sú už nastavené geneticky (čo je reprezentované binárnymi hodnotami 0 a 1 v genotype agenta), iné parametre siete nie sú nastavené (čo je reprezentované symbolmi # v genotype agenta), tak napríklad chromozóm dĺžky 16 je lineárny reťazec obsahujúci symboly 0, 1, a #,

$$\mathbf{x} = (1100#####01##0011).$$

V priebehu evolúcie agenta sa genotyp agenta (chromozóm) mení pomocou mutácii tak, že sú mutované tak binárne hodnoty genotypu ako aj symboly #. Pod **učeníím agenta** rozumieme proces, kde agent metódou „hill climbing“ (t. j. náhodným lokálnym prehľadávaním) skúma, ktoré symboly # môžu byť nahradené nejakou binárnou hodnotou 0 alebo 1. Ukazuje sa, že väčšina symbolov # je nahradená binárnymi hodnotami, čo môžeme interpretovať tak, že kognitívny orgán agenta sa stáva vhodnejším pre realizáciu požadovaných kognitívnych aktivít. Tento proces prebieha aj bez učenia, ale je podstatne pomalší.

Hlavný výsledok týchto numerických experimentov je ten, že ak do procesu evolúcie zapojíme učenie, potom **emergencia** chromozómov v populácii s malou frekvenciou výskytu allelu # je podstatne rýchlejšia ako keď učenie nie je zapojené. Výsledkom evolúcie je agent, ktorý má vo svojom kognitívnom orgáne určité poznatky buď

- (1) už **priamo zabudované** v jeho architektúre (inštinkty) alebo
- (2) jeho kognitívny orgán má **určité predispozície** vykonávať špeciálne kognitívne aktivity (napr. schopnosť reči).

4.1.2 Plasticita genotypu

Pristúpime k formulácii koncepcie efektívneho fitness, ktorý hrá dôležitú úlohu pri formulácii Baldwinovho efektu pomocou genetického algoritmu. **Plasticita fenotypu** je vyjadrená skutočnosťou, že fitness fenotypu $f(\mathbf{x})$ môže byť prehľadávaný v okolí $U(\mathbf{x})$ metódou „hill climbing“. V okolí $U(\mathbf{x})$ hľadáme „lepšie riešenie“ $\mathbf{x}' \in U(\mathbf{x})$, pre ktoré platí $f(\mathbf{x}') > f(\mathbf{x})$. Použitie koncepcie **efektívneho fitness** spočíva v nasledujúcej možnosti vyjadriť fitness chromozómu \mathbf{x} : Majme dva chromozómy \mathbf{x}_1 a \mathbf{x}_2 s rovnakým fitness, $f(\mathbf{x}_1) = f(\mathbf{x}_2)$, pričom v blízkom okolí týchto chromozómov existujú riešenia – chromozómy

$$\mathbf{x}_{1,opt} = \arg \min_{\mathbf{x} \in U(\mathbf{x}_1)} f(\mathbf{x}), \quad \mathbf{x}_{2,opt} = \arg \min_{\mathbf{x} \in U(\mathbf{x}_2)} f(\mathbf{x}) \quad (4.1)$$

Ak tieto chromozómy vyhovujú podmienke

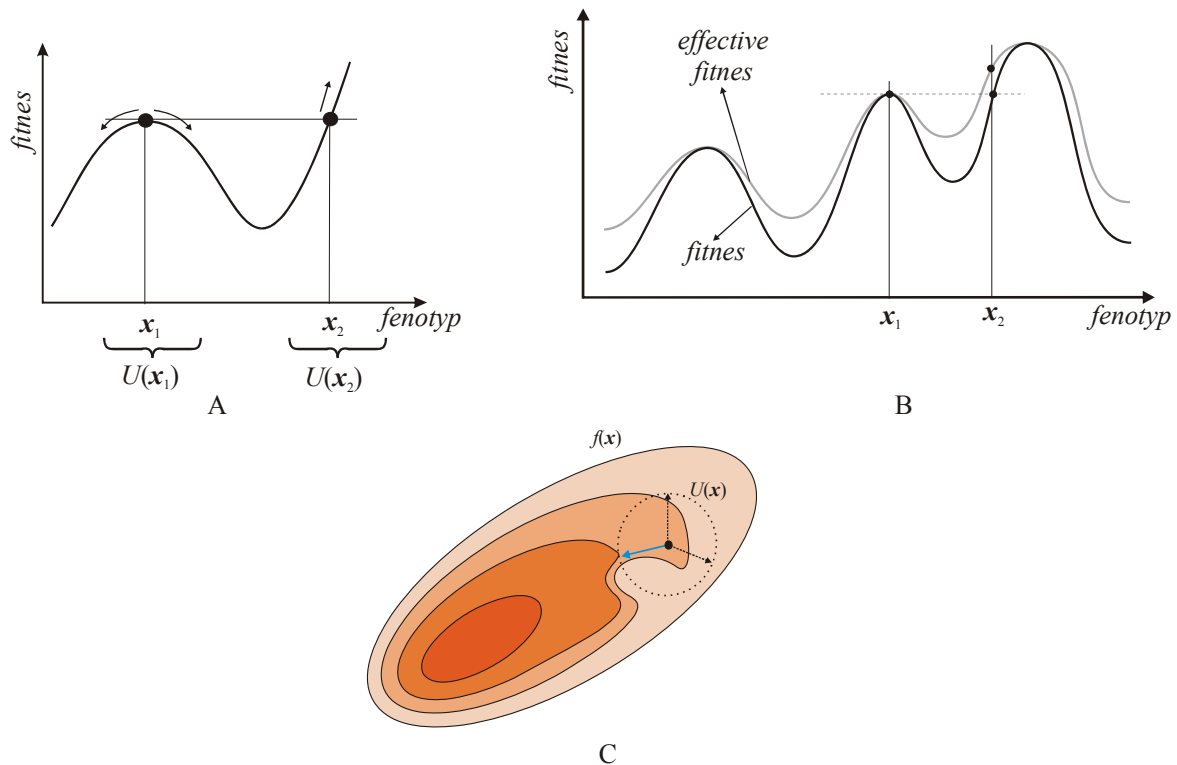
$$f(\mathbf{x}_{1,opt}) > f(\mathbf{x}_{2,opt}) \quad (4.2)$$

lebo pomocou **efektívnych fitness** $F(x_1) = f(x_{1,opt})$ a $F(x_2) = f(x_{2,opt})$ túto vlastnosť vyjadríme ako

$$F(x) > f(x) \quad (4.3)$$

Môžeme teda konštatovať, že **efektívne fitness** odráža vlastnosti fenotypu v jeho blízkom na povrchu funkcie fitness $f(x)$

1. $f(x_1) = f(x_2) \Rightarrow F(x_1) = F(x_2)$, potom fenotypy x_1 a x_2 sú **efektívne rovnocenné**,
2. $f(x_1) = f(x_2) \Rightarrow F(x_1) > F(x_2)$, potom fenotyp x_1 je **efektívne lepší** ako fenotyp x_2 .



Obrázok 4.3. Grafická interpretácia koncepcie efektívneho fitness. (A) Tento diagram znázorňuje situáciu, keď dva chromozómy x_1 a x_2 majú rovnaké fitness, avšak v okolí chromozómu x_2 existujú „stavy“ s vyšším fitness ako je $f(x_2)$. To znamená, že pre evolučný proces je tento chromozóm podstatne dôležitejší ako chromozóm x_1 , v ktorého blízkosti neexistujú chromozómy s vyšším fitness. Túto skutočnosť môžeme formulovať pomocou efektívneho fitness tak, že efektívne fitness v x_1 je menšie ako efektívne fitness v x_2 . Ak je selekcia riadená efektívnym fitness, potom druhý chromozóm je v prirodzenom výbere preferovaný pred chromozómom x_1 . (B) Znáročenie priebehu efektívneho fitness $F(x)$ vzhľadom k fitness $f(x)$, ako vyplýva z obrázku, vždy platí $F(x) \geq f(x)$. (C) Alternatívne znázornenie významu efektívneho fitness na jeho povrchu. V štandardnom genetickom algoritme generovanie nového chromozómu x' z pôvodného chromozómu je náhodné, avšak ak použijeme efektívnu fitness, potom určitý smer je nádejny a ten je zvolený ako následovník pôvodného x .

Môžeme teda konštatovať, že koncepcia efektívneho fitness nám slúži k zefektívneniu genetického algoritmu: (1) Hovoríme, že **učenie** nám pomáha nájsť lokálne nádejny smer (evolvabilitu) pre nasledujúcu evolúciu, (2) V štandardnom prístupe Darwinovej evolúcie evolvabilita sa ponecháva výlučne na prírodný výber, a (3) Zapojenie Baldwinovho efektu do evolúcie môže slúžiť ako významný akceleračný faktor Darwinovej evolúcie. Samozrejme, tieto tri dôležité aspekty zapojenia učenia do genetického algoritmu sú efektívny akceleračným faktorom len vtedy, ak „učenie“ je možné efektívne realizovať ako lokálne prehľadávanie metódou „hill climbing“. Ako jednoduchý kontrapríklad nevhodnosti učenia

pre zefektívnenie genetického algoritmu je možný prípad, keď aktivovanie funkcie $f(\mathbf{x})$ (t. j. výpočet fitness chromozómu \mathbf{x}) je časovo veľmi náročný proces.

4.1.2 Formulácia GA s učením

Zopakujeme si základné princípy genetického algoritmu s kapitoly 1.2. Nech chromozóm $\mathbf{x} = (x_1, x_2, \dots, x_n) \in \{0, 1, \#\}^n$ je lineárny reťazec dĺžky n , ktorý obsahuje symboly 0, 1 a #. Nech si optimálny (cieľ evolúcie GA) chromozóm \mathbf{x}_{opt} je náhodne generovaný binárny vektor dĺžky n

$$\mathbf{x}_{opt} = (x_1^{opt} x_2^{opt} \dots x_n^{opt}) \in \{0, 1\}^n \quad (4.4)$$

Populácia P je multimnožina obsahujúca p chromozómov

$$P = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_p\} \subseteq \{0, 1, \#\}^n \quad (4.5)$$

Každý chromozóm $\mathbf{x} \in P$ je ohodnotený **fitness**. Tento ohodnocovací proces úzko súvisí s procesom učenia a je určený takto: Nech okolie chromozómu $\mathbf{x} \in P$ je

$$U(\mathbf{x}) = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_q\} \subseteq \{0, 1\}^n \quad (4.6)$$

Toto okolie obsahuje q binárnych vektorov, ktoré sú náhodne vytvorené z chromozómu \mathbf{x} tak, že jeho „hash“ symboly sú náhodne nahradené 0 alebo 1

$$\mathbf{y} = (y_1 y_2 \dots y_n) \in \{0, 1\}^n \quad \text{a} \quad y_i = \begin{cases} x_i & (\text{if } x_i = 0 \text{ or } x_i = 1) \\ \text{random}(2) & (\text{if } x_i = \#) \end{cases} \quad (4.7)$$

Kardinalita $q = |U(\mathbf{x})|$ sa nazýva *rozsah učenia*. Funkcia $d(\mathbf{x})$, pre $\mathbf{x} \in P$, je špecifikovaná ako minimálna vzdialenosť medzi optimálnym chromozómom \mathbf{x}_{opt} a binárnym vektorom z okolia $U(\mathbf{x})$

$$d(\mathbf{x}) = \min_{\mathbf{y} \in U(\mathbf{x})} |\mathbf{y} - \mathbf{x}_{opt}| \quad (4.8)$$

Efektívne fitness chromozómu \mathbf{x} je určené formulou

$$F(\mathbf{x}) = e^{-\xi d(\mathbf{x})} \quad (4.9)$$

kde ξ je tzv. koeficient strmosti, ktorý špecifikuje „ostrosť“ fitness funkcie. Proces učenia je špecifikovaný dvoma parametrami: (1) kardinalitou q okolia $U(\mathbf{x})$ a (2) parameter strmosti ξ . Pre asymptotické hodnoty $F(\mathbf{x})$ platí

$$\lim_{\xi \rightarrow \infty} F(\mathbf{x}) = \begin{cases} 1 & (\text{if } \mathbf{x} = \mathbf{x}_{opt}) \\ 0 & (\text{if } \mathbf{x} \neq \mathbf{x}_{opt}) \end{cases} \quad \text{a} \quad \lim_{\xi \rightarrow 0} F(\mathbf{x}) = f_{max} \quad (4.10)$$

Obyčajné fitness $f(\mathbf{x})$ má tento jednoduchý priebeh


$$f(\mathbf{x}) = \begin{cases} 1 & (\text{pre } \mathbf{x} = \mathbf{x}_{opt}) \\ 0 & (\text{pre } \mathbf{x} \neq \mathbf{x}_{opt}) \end{cases} \quad (4.11)$$

Potom platí pre každý chromozóm \mathbf{x} podmienka (pozri obr. 4.4)

$$f(\mathbf{x}) \geq F(\mathbf{x}) \quad (4.12)$$

Podľa Hintona a Nowlana [xx] študovaný problém môže byť charakterizovaný ako hľadanie ihly v kope sena (ang. *needle in a haystack*) dôsledku skutočnosti, že existuje len jedno korektné riešenie v priestore 2^n riešení. Fitness je obvykle významnou heuristikou, ktorá nám uľahčuje toto hľadanie optimálneho riešenia. Obyčajné fitness $f(\mathbf{x})$ nie je nám však nápomocné v tomto prehľadávaní, z jeho definície (4.11) vypláva, že je jednotkové v prípade, že $\mathbf{x} = \mathbf{x}_{opt}$, v opačnom prípade je nulové (pozri obr. 4.4). To znamená, že k tomu, aby sme

našli správne riešenie (t. j. ihlu v kope sena), musíme prekontrolovať všetky prípustné riešenia, čo je vlastne ten najhorší možný algoritmus riešenia daného problému. Avšak, ak používame efektívne fitness, ktoré je nenulové aj v blízkom okolí hľadaného riešenia, máme podstatne väčšiu šancu nájsť vsprávne riešenie. Môžeme povedať, že efektívne fitness nás proces prehľadávania naviguje smerom, kde sú väčšie hodnoty efektívneho fitness.



Obrázok 4.4. Priebeh fitness $f(x)$ a efektívneho fitness $F(x)$. Poznamenajme, že fitness $f(x)$ je nenulové len pre jeden konkrétny binárny chromozóm x_{opt} , pre všetky ostatné chromozómy je nulové. Efektívne fitness je nenulové aj pre chromozómy z blízkeho okolia optimálneho chromozómu x_{opt} .

Podľa Hintona a Nowlana študovaný problém môže byť charakterizovaný ako hľadanie ihly v kope sena; pretože existuje len jedno korektné riešenie v priestore 2^n riešení. Ak je do GA zahrnuté aj učenie, potom GA môže byť interpretovaný ako metóda prehľadávania, kde „niekto“ radí chromozómu v ktorom „smere je ihla“. Ak do GA nie je zahrnuté učenie, GA môže byť interpretované zhruba ako metóda prehľadávania, kde nik neradí "chromozómu", ktorým „smerom je ihla“. Naznačenú teóriu GA učením sme realizovali pre tieto parametre:

- (1) n , dĺžka chromozómu ($n=20$),
- (2) p , veľkosť populácie ($p=500$),
- (3) P_{cross} , pravdepodobnosť kríženia ($P_{cross}=0.1$),
- (4) P_{mut} , pravdepodobnosť mutácie ($P_{mut}=0.01$),
- (5) t_{max} , počet epoch ($t_{max}=200$),
- (6) q , veľkosť učenia ($q=10$),
- (7) ξ , parameter strmosti ($\xi=0.1 - 1.0$),
- (8) maximálna hodnota fitness $f_{max}=2.0$,
- (9) minimálna hodnota fitness $f_{min}=1.0$,
- (10) prvotná populácia je náhodne generovaná tak, že jej chromozómy obsahujú 50% symbolov #, 25% symbolov 0, and 25% symbolov 1.


Numerické výpočty realizované pomocou týchto parametrov sú znázornené na obrázku 4.4. Z týchto výsledkov jednoznačne vyplýva, že zapojenie učenia do GA podstatne akceleruje túto metódu. Navyše, jednoduché kognitívne úlohy môžu byť pomocou Baldwinovho efektu kanalizované (geneticky zakódované - vznik inštinktov sociálneho hmyzu) do genotypu organizmu. Zložité kognitívne úlohy nemôžu byť však pomocou Baldwinovho efektu kanalizované, pretože dĺžka života nie je postačujúca k prejavu sa tohto efektu.

Pomocou metafory učenia môžeme genetické algoritmy rozdeliť do troch skupín:

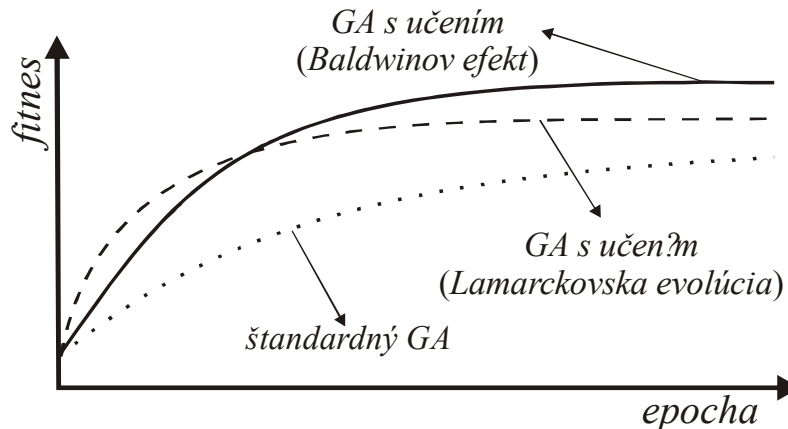
- (1) **Štandardné genetické algoritmy**, kde selekcia chromozómov do reprodukčného procesu je vyberaná na základe ich obyčajného fitness, ktoré je určené ako zobrazenie chromozómov (binárnych reťazcov fixnej dĺžky) na kladné reálne číslo.
- (2) **Modifikované genetické algoritmy s učením**, kde selekcia chromozómov do reprodukcie je riadená pomocou efektívnej fitness (t. j. GA s Baldwinovým efektom),

avšak kde vstupné chromozómy do reprodukčného procesu sa nezamieňajú za optimálne chromozómy z ich blízkeho okolia, t. j. genetické algoritmy si zachovávajú svoj darwinovský charakter.

- (3) Genetické algoritmy s procesom učenia, kde pri reprodukčnom procese vybrané chromozómy sú už lokálne optimalizované. Takto modifikovaný genetický algoritmus už nemá charakter darwinovskej evolúcie, ale má charakter tzv. ***lamarckovskej evolúcie***.




Obrázok 4.4. (A) Päť rôznych priebehov fitness pre rôzne hodnoty parametrov strmosti, od podporovaného učenia ($\xi=0.1$) až po potlačené učenie ($\xi=1.0$). (B) Priebehy frakcií korektných allel, nekorektných allel a „hash“ allel (#) pre GA s parametrom strmosti $\xi=0.5$.



Obrázok 4.5. Znázornenie rôznych typov evolúcie v rámci genetických algoritmov. (A) Priebeh fitness štandardného GA (bodkovaná čiara) ukazuje, že priemerné fitness rastie pomaly ale monotónne do maximálnej hodnity. (B) Priebeh fitness GA s učením (spojitá čiara ———) ukazuje, že algoritmus je podstatne rýchlejší ako štandardný GA. (C) Priebeh fitness GA s lamarckovskou evolúciou (prerušovaná čiara - - - -) rastie najrýchlejšie, avšak algoritmus obvykle skončí v lokálnom minime.

Znázornenie evolúcie vo všetkých týchto troch prípadoch je ukázané na obrázku 4.5. Ak rozšírime štandardný genetický algoritmus o učenie (t. j. zahrnieme Baldwinov efekt) vznikne nová forma genetického algoritmu, ktorá je akcelerovaná pred pôvodnou štandardnou verziou a navyše nemá tendenciu konvergovať do blízkeho lokálneho minima. Na obrázku je znázornená aj tretia verzia genetického algoritmu, kde pri prehľadávaní lokálneho minima v rámci okolia vybraného rodičovského chromozómu dochádza k jeho zámene za lokálne optimálny chromozóm. Toto rozšírenie genetického algoritmu je mimo rámca darwinovskej


evolúcie a môže byť považované za lamarckovskú verziu evolúcie genetického algoritmu, kde chromozómy dedia získané vlastnosti v priebehu ich existencie (táto metafora lamarckovskej evolúcie je často vyjadrená diktumom „svaly kováča dedia jeho deti“. Z obr. 4.5 vidieť, že táto lamarckovská verzia genetického algoritmu konverguje najrýchlejšie z oboch predchádzajúcich verzí, ale žiaľ veľmi často do lokálneho extrému.



Obrázok 4.6. Anglický evolučný biológ Richad Dawkins (1941-), ktorý v r. 1978 publikoval slávnu knihu „The Selfish Gene“ v ktorej formuloval mémetikú - vedu o mémoch, ktoré sú reprezentované informačnými jednotkami kopírujúce sa z jedného mozgu na druhý mozog pomocou imitácie. Taktiež postulov, že mémy sú replikátory, ktoré môže byť predmetom evolúcie. Memetika poskytuje konceptuálne jednoduché vysvetlenie o podstate a evolúcii ľudskej kultúry, paradigma mémov ako replikátorov je veľmi zaujímavým prístupom pre komunitu umelej inteligencie a kognitívnej vedy.

4.2. Dawkinsova memetika

Môžeme sa zamýšľať nad tým, ako ďalej akcelerovať darwinovskú evolúciu. V predchádzajúcej časti tejto kapitoly už sme študovali možnosť akcelerácie pomocou Baldwinovho efektu, kde štandardná fitness je v procese selekcie nahradená efektívnou fitness. Ďalšia možnosť akcelerácie darwinovskej evolúcie existuje pomocou Dawkinsových mémov, ktoré obsahujú čiastočnú informáciu o hľadanom optimálnom riešení. Z tohto pohľadu môžeme teda rozlišovať tri stupne Darwinovej evolúcie (pozri obrázok 4.6):




Obrázok 4.6. Schématické znázornenie troch stupňov darwinovskej evolúcie pomocou hypotetického agenta s kognitívnym orgánom reprezentovaným neuronovou sieťou. Táto sieť je špecifikovaná fenotypom – chromozómom. V 1. stupni neexistuje spätná interakcia (učenie) medzi chromozómom a neuronovou sieťou, chromozóm „na tvrdo“ špecifikuje neuronovú sieť, zmeny v architektúre tejto siete sú možné len pomocou „neriadenej“ mutácie. V 2. stupni existuje už proces učenia, čiže môže dochádzať k zmenám neuronovej siete pomocou „riadených“ mutácií. V 3. stupni darwinovskej evolúcie okrem učenia je do procesu výpočtu efektívneho fitness zapojený aj mém, ktorý reprezentuje „informáciu“ o optimálnom riešení.


- 1. stupeň.** Fitness genotypu agenta je určený *výlučne len jeho zložením*, žiadne iné efekty (učenie sa, mémy, ...) nie sú zahrnuté pri ohodnotení genotypu fitnessom, tento prvý stupeň je reprezentovaný štandardným genetickým algoritmom..

2. **stupeň.** Fitness genotypu je určené nielen jeho štruktúrou, ale aj *schopnosťou organizmu učiť sa* (Baldwinov efekt). Elementárne kognitívne aktivity môžu byť zabudované (kanalizované) do genotypu organizmu (napr. pri vzniku sociálneho hmyzu), tento stupeň je reprezentovaný genetickým algoritmom, ktorý v procese selekcie využíva efektívne fitness.
3. **stupeň.** Fitness genotypu je určené nielen jeho štruktúrou a schopnosťou organizmu učiť sa, ale aj určitým „*informačným balíkom*“ (*mémom*), ktorý podstatne ovplyvňuje fitness.

Ako môžu ovplyvňovať mémy kognitívny orgán (neurónovú sieť) agenta. Pre jednoduchosť predpokladajme, že mém – informácia je poznať zakódovaný vo forme implikácie $\alpha \Rightarrow \beta_{req}$, potom neurónovú sieť môžeme adaptovať tak, že na vstup α reaguje výstupom β , ktorý je skoro totožný s požadovaným výstupom β_{req} , pozri obrázok 4.7.



Obrázok 4.7. Učenie kognitívneho orgánu (mozgu) pomocou mému štruktúry $\alpha \Rightarrow \beta_{req}$. Premisa mému α je vstupom do kognitívneho orgánu, a nech jeho odozva na tento vstup je β . Požadovaný výstup β_{req} je porovnaný s vypočítaným výstupom β (úloha učiteľa / tútora), toto porovnanie vyústi v konštrukciu Δw , pomocou ktorého sa upraví kognitívny orgán tak, aby sa zmenšil rozdiel medzi vypočítaným β a požadovaným β_{req} . Vnútrotná (skrytá) premenná σ reprezentuje vnútorný stav mozgu, ktorý ovplyvňuje odozvu mozgu na daný vstup, $\beta = F(\alpha, \sigma; w)$ (odozva mozgu na dva rovnaké vstupy $\alpha_1 = \alpha_2$, avšak pre rôzne vnútorné stavy $\sigma_1 \neq \sigma_2$, môže byť diametrálne odlišná, $\beta_1 \neq \beta_2$).




Obrázok 4.8. (A) Vznik m-chromozómu ako komplexu chromozómu x a mému m . (B) Predmetom evolúcie v memetickom prístupe je populácia m-chromozómov.

4.2.1 Formulácia GA s učením a memetickým prenosom informácie


Použijeme veľmi zjednodušený *model mémov*, ktorý môže byť jednoducho zahrnutý do GA s učením. Mémy budeme chápať ako lineárne reťazce (rovnakej dĺžky ako gény), ktoré spolu s génmi vytvárajú komplex nazývaný *m-chromozóm*, $\alpha = (x, m)$ (pozri diagram A na obrázku 4.8.). Mémy sú nositeľom informácie o najlepšom lokálnom riešení, ktoré bolo doposiaľ nájdené v priebehu evolúcie GA. Využitie mémov je dôležité v procese ohodnotenia m-chromozómov *fitness*, ako ďalší zdroj informácie o aktuálnom najlepšom riešení. Na začiatku evolučného procesu sú mémy prázdne (majú nulový informačný obsah). V priebehu evolučného procesu mémy sa stávajú nositeľom informácie, ktorá sa šíri v populácii pomocou *mémentickej interakcie*. Budeme rozlišovať dva typy memetickej interakcie:

(1) **Horizontálna memetická interakcia**, kde kvázináhodne vybraný (s vysokým fitness) m-chromozóm - donor s príslušným mémom vytvára správu – mém, ktorá je **prenesená** (mierne zmutovaná) do náhodne vybraného m-chromozómu – akceptoru, ktorý prijme túto správu a zahrnie ju do svojho m-chromozómu (pozri obrázok 4.9).

(2) **Vertikálna memetická interakcia**, v rámci reprodukčného procesu vytváraný potomkovia obsahujú mém (mierne zmutovaný) od jedného zo svojich rodičov; budeme používať model, kde “matka” určuje mém svojho potomka (hovoríme, že matka vychováva potomka) (pozri obrázok 4.10)



Obrázok 4.9. Horizontálna interakcia medzi dvoma m-chromozómami donorom a akceptorom, pričom donor je kvázináhodne vybraný s pravdepodobnosťou úmernou fitness, jeho mém je v ľahko zmutovanej forme prenesený do m-chromozómu



Obrázok 4.10. Vertikálna interakcia medzi rodičovským m-chromozómom a potomkovským m-chromozómom, kde mém z rodiča v ľahko zmutovanej forme prechádza na potomka. V tomto prípade musíme z populácie odstrániť náhodne vybraný m-chromozóm, aby sme zachovali celkový počet m-chromozómov v populácii.

Pristúpime teraz k formulácii mémov a ich komplexov s chromozómami. **Mém** je reťazec n symbolov 0, 1 a *

$$\mathbf{m} = (m_1 m_2 \dots m_n) \in \{0, 1, *\}^n \quad (4.13)$$

Šírka mému \mathbf{m} , označená $|\mathbf{m}|$, je určená počtom binárnych (nehviezdičkových) symbolov, napr. mém $\mathbf{m}=(01**01***)$ má šírku $|\mathbf{m}|=4$. Mém budeme používať ako pomocný nositeľ informácie získanej v rámci procesu učenia. Ak šírka mému je nulová, potom hovoríme, že mém neobsahuje vhodnú informáciu a jeho aplikácia v rámci evolučného procesu je bezpredmetná.

Memetický chromozóm (*m-chromosome*) je určený ako usporiadaná dvojica chromozómu a mému o rovnakej dĺžke

$$\alpha = (\mathbf{x}, \mathbf{m}) = ((x_1 x_2 \dots x_n), (m_1 m_2 \dots m_n)) \in \{0, 1, \#\}^n \times \{0, 1, *\}^n \quad (4.14)$$

Kde $\alpha = (\mathbf{x}, \mathbf{m}) = ((x_1, x_2, \dots, x_n), (m_1, m_2, \dots, m_n))$ je m-chromozóm s časťami \mathbf{x} a \mathbf{m} . Populácia P je multimnožina obsahujúca p m-chromozómov

$$P = \{\alpha_1, \alpha_2, \dots, \alpha_p\} \subseteq \{0, 1, \#\}^n \times \{0, 1, *\}^n \quad (4.15)$$

Proces učenia v ktorom sú m-chromozómy ohodnotené fitness obsahuje dve etapy:

- V *prvej etape* mémetická časť \mathbf{m} m-chromozómu α je použitá na opravu (modifikáciu) chromozómovej časti \mathbf{x} . Tento proces spočíva v tom, že „hash“ symboly v \mathbf{x} sú nahradené príslušnými binárnymi symbolmi (ak existujú) 0/1 z mému. Pre ilustráciu tejto etapy uvažujme m-chromozóm

$$\alpha = \left(\underbrace{00\#\#1\#0\#}_x \right) \left(\underbrace{11***0**}_m \right) \quad (4.16)$$

Opravený chromozóm $\hat{\mathbf{x}}$ vznikne z chromozómu \mathbf{x} nahradením symbolov # binárnymi symbolmi z mému \mathbf{m}

$$\mathbf{x} = (00\#\#1\#0\#)$$

$$\mathbf{m} = (11***0**)$$

$$\hat{\mathbf{x}} = (00\#\#100\#)$$

Kde sme v šiestej polohe symbol # nahradili binárnym symbolom 0 z mému \mathbf{m} .

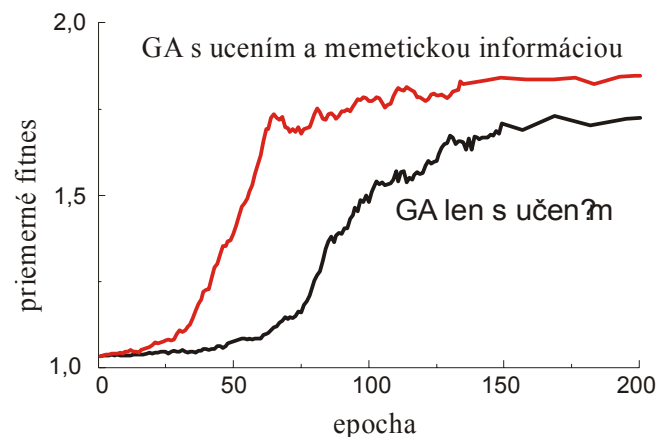
- V *druhej etape*, pre modifikovaný chromozóm $\hat{\mathbf{x}}$ vytvoríme okolie $U(\hat{\mathbf{x}})$, pomocou tohto okolia spočítame minimálnu vzdialenosť od \mathbf{x}_{opt}

$$d_{min} = \min_{y \in U(\hat{\mathbf{x}})} (\mathbf{y} - \mathbf{x}_{opt}) \quad (4.17)$$

Potom efektívne fitness priradené m-chromozómu α je určené formulou

$$f(\alpha) = e^{-\xi d_{min}} \quad (4.18)$$

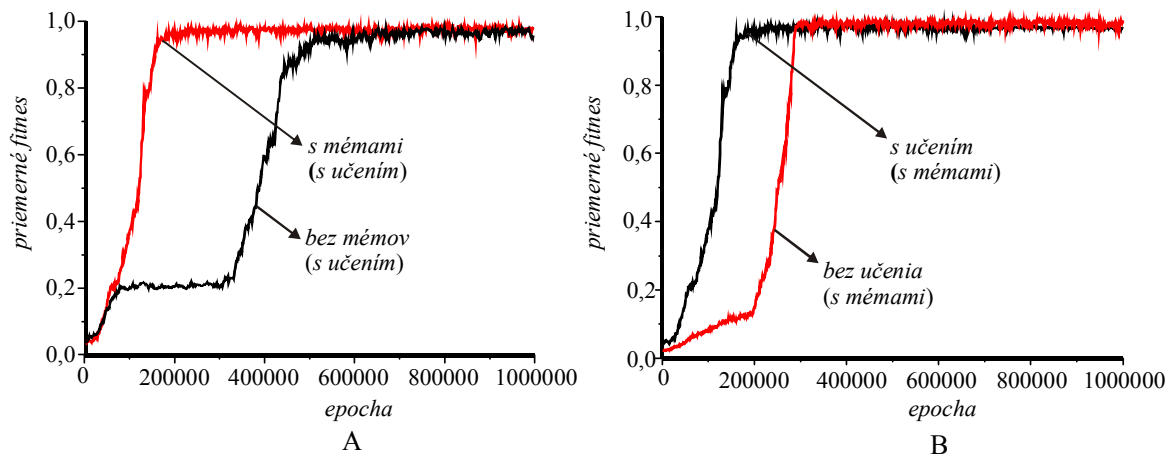
Týmto sme zavřšili špecifikáciu genetického algoritmu, kde populácia P je tvorená m-chromozómami a proces selekcie m-chromozómov do reprodukčného procesu je založený na efektívnom fitness (4.18).



Obrázok 4.11. Priebeh priemerného fitness pre dve rôzne verzie GA s a bez memetickej informácie, keď učenie (Baldwinov efekt) je zahrnutý v oboch verziách, pričom parameter strmosti učenia je $\xi=0.5$. Vidíme, že GA s učením a s memetickou informáciou podstatne rýchlejšie konverguje k maximálnej hodnote fitness než ako GA len s učením bez zahrnutia memetickej informácie.

Na obrázku 4.11 sú znázornené výsledky našich simulačných výpočtov v dvoch verziách so zahrnutím učenia, ale jedna verzia neobsahuje memetickú informáciu, zatiaľ čo druhá verzia ju

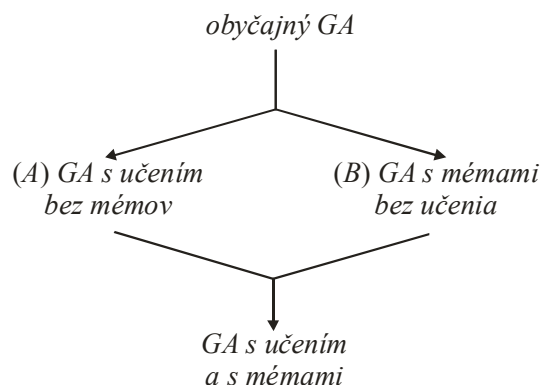
obsahuje . Vidíme, že zahrnutie mémov do GA s učením podstatne zvyšuje jeho efektívnosť. Môžeme povedať, že memy do určitej miery substituujú proces učenia. Ak je process učenia “drahý”, potom prístup mémov je dôležitý factor prekonania barrier učenia. Podobné výsledky sú prezentované aj na obrázku 4.12. Diagram A obsahuje porovnanie GA algoritmu s mémami a bez mémov (v oboch prípadoch s učením). Podobne, diagram B obsahuje dva priebehy priemerného fitness s učením a bez učenie (v oboch prípadoch mémy sú zahrnuté).



Obrázok 4.12. (A) Dva priebehy priemerného fitness pre GA so zahrnutím učenia (Baldwinovým efektom), ktoré sa odlišujú tým, že mémy sú alebo nie sú zahrnuté. (B) . Dva priebehy priemerného fitness pre GA so zahrnutím mémov, ktoré sa odlišujú len tým, či učenie je al bo nie je zahrnuté.

Prezentované numerické výsledky ukazujú, že GA môžeme usporiadať do postupnosti s monotónnym zvyšovaním efektivity (pozri obrázok 4.13)

- (a) Štandardný GA, fitness je určené len štruktúrou chromozómu,
- (b) GA s učením (Baldwinov efekt), fitness chromozómu je určené prehľadávaním okolia daného chromozómu (tento process sa nazýva učenie),
- (c) GA s učením a mémami (Baldwinov efekt plus mémy).



Obrázok 14.13. Rozdelenie GA do rôznych kategórií so zahrnutím/ bez zahrnutia učenia a mémov, idúc zhora nadol efektívnosť GA monotónne rastie.

Výsledky môžeme zhrnúť do týchto záverov:

1. Zahrnutie učenia (Baldwinovho efektu) a Dawkinsových mémov do GA je významným intenzifikačným faktorom genetických algoritmov. Zhruba možno konštatovať, že efektívnosť akcelerácia GA týchto diametrálne odlišných prístupov je rovnaké. Oba

prístupu odlišnými mechanizmami napomáhajú prekonať medzigeneračné informačné bariéry prostriedkami, ktoré zachovávajú charakter darwinovej evolúcie.

2. Pomocou memetického prístupu môžeme interpretovať prostriedkami multiagentových systémov význam kultúry v sociálnych systémov ako významného faktora akcelerácie evolúcie pomocou medzigeneračného prenosu poznatkov (význam kultúrnej alebo spoločnej pamäti) v sociálnych vedách.