

Cvičenia


Cvičenie 4.1. Ako je definovaný Baldwinov efekt? Aký má význam Baldwinov efekt pre kognitívnu vedu?

Riešenie. V r.1896 americký psychológ J. M. Baldwin formuloval hypotézu podľa ktorej, jedinci z populácie *schopní učiť sa majú väčšiu šancu prežitia*, ich fitness je väčšie ako fitness 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*.

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

Cvičenie 4.2. Popíšte model Hintona a Nowlana Baldwinovho efektu. Ako je realizované “učenie” v tomto prístupe?

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



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 #,

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

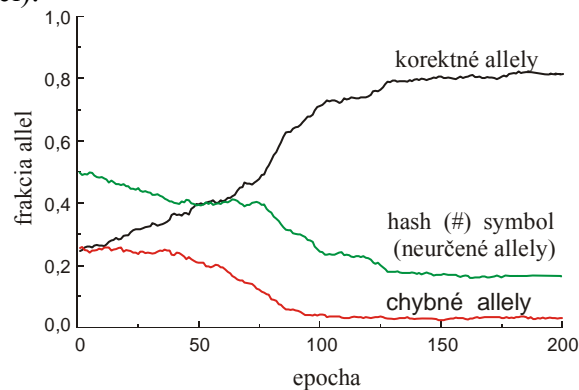
V priebehu evolúcie agenta sa genotyp agenta (chromozóm) mení pomocou mutácii tak, že sú mutované tak binárne hodnoty genotypu ako aj symboly #. Pod *učením agenta* rozumieme proces, kde agent metódou „hill climbing“ (t. j. náhodným lokálnym prehľadávaním) skúma, ktoré symboly # môžu byť nahradené nejakou 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

allel # 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 (inštinky) alebo

(2) jeho kognitívny orgán má **určité predispozície** vykonávať špeciálne kognitívne aktivity (napr. schopnosť reči).



Cvičenie 4.3. Čo je to plasticita genotype? Ako sa pomocou plasticity genotype realizuje učenie? Čo je to efektívna fitness? Aká je grafická interpretácia efektívnej fitness?

Riešenie. Koncepcia **efektívneho fitness** 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

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

Ak tieto chromozómy vyhovujú podmienke

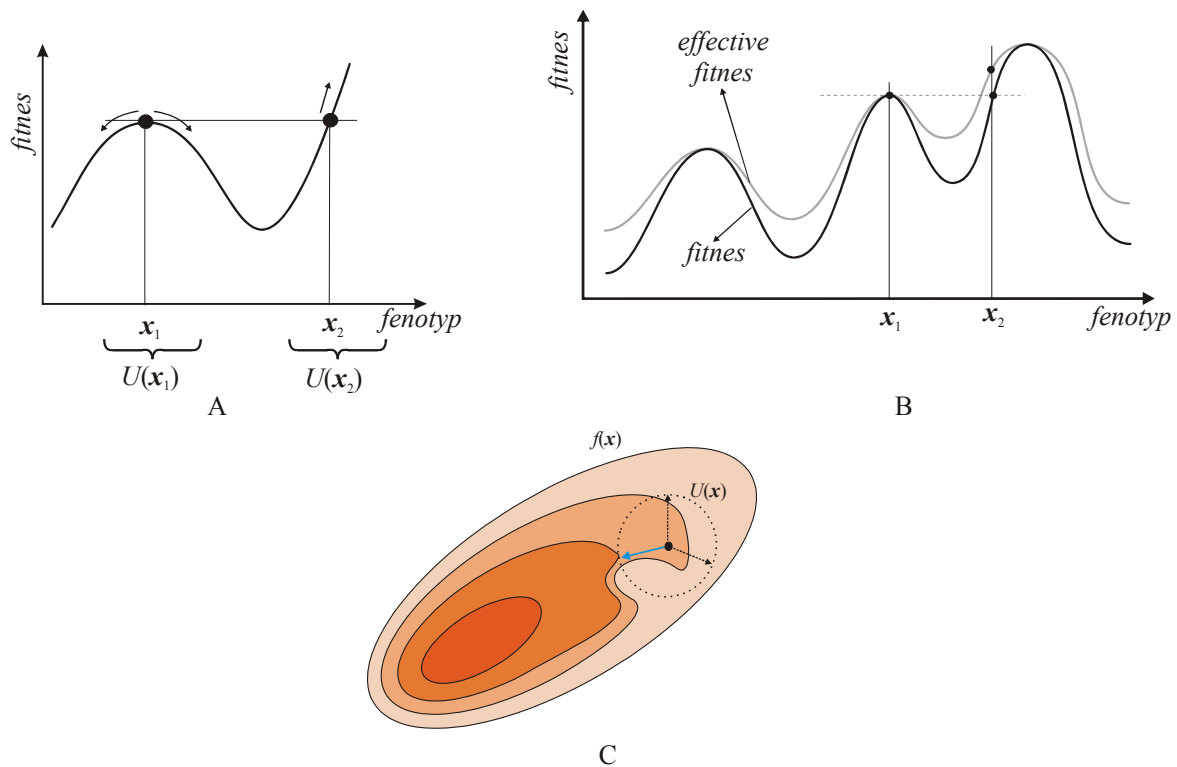
$$f(\mathbf{x}_{1,opt}) > f(\mathbf{x}_{2,opt})$$

lebo pomocou **efektívnych fitness** $F(\mathbf{x}_1) = f(\mathbf{x}_{1,opt})$ a $F(\mathbf{x}_2) = f(\mathbf{x}_{2,opt})$ túto vlastnosť vyjadrím ako

$$F(\mathbf{x}_1) > F(\mathbf{x}_2)$$

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

1. $f(\mathbf{x}_1) = f(\mathbf{x}_2) \Rightarrow F(\mathbf{x}_1) = F(\mathbf{x}_2)$, potom fenotypy \mathbf{x}_1 a \mathbf{x}_2 sú **efektívne rovnocenné**,
2. $f(\mathbf{x}_1) = f(\mathbf{x}_2) \Rightarrow F(\mathbf{x}_1) > F(\mathbf{x}_2)$, potom fenotyp \mathbf{x}_1 je **efektívne lepší** ako fenotyp \mathbf{x}_2 .



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.

Cvičenie 4.4. Aká je formulácia GA s učením?

Riešenie. 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

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

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 $U(\mathbf{x})$

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

Efektívne fitness chromozómu \mathbf{x} je určené formulou

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

kde ξ je tzv. koeficient strmosti, ktorý špecifikuje „ostrostr“ 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

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

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

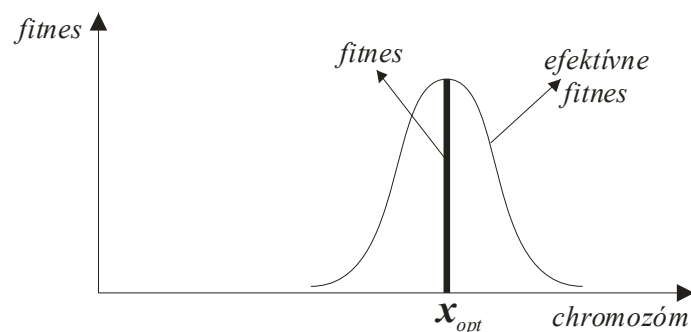
$$f(\mathbf{x}) = \begin{cases} 1 & (\text{pre } \mathbf{x} = \mathbf{x}_{opt}) \\ 0 & (\text{pre } \mathbf{x} \neq \mathbf{x}_{opt}) \end{cases}$$

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

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

Cvičenie 4.5. Vysvetlite metaforu „hľadanie ihly v kope sena“ pre genetický algoritmus s učením, aká je úloha efektívneho fitness vo vysvetlení tejto metafory?

Riešenie. 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 prehladávaní, toto fitness je jednotkové len pre $\mathbf{x} = \mathbf{x}_{opt}$, v opačnom prípade je nulové. 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 pomocou efektívneho fitness proces prehladávania je navigovaný smerom, kde sú väčšie hodnoty efektívneho fitness.




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“.

Cvičenie 4.6. Ako môžeme rozdeliť pomocou metafory genetické algoritmy do troch skupín? Znázornite priebeh priemerného fitness pre jednotlivé skupiny genetického algoritmu.

Riešenie. 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**.




Znázornenie evolúcie vo všetkých týchto troch prípadoch je ukázané na obrázku. 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 obrázku vidieť, že táto lamarckovská verzia genetického algoritmu konverguje najrýchlejšie z oboch predchádzajúcich verzií, ale žiaľ veľmi často do lokálneho extrému.

Cvičenie 4.7. Ako je špecifikovaný podľa Dawkinsa mém? Aké stupne Darwinovej evolúcie môžeme rozlišovať úpomocou zapojenia učenia a mémov?

Riešenie. Anglický evolučný biológ Richad Dawkins (1941-) v r. 1978 publikoval slávnu knihu „The Selfish Gene“ v ktorej formuloval mémontiku - vedu o mémoch, ktoré sú reprezentované informačnými jednotkami kopírujúce sa z jedného mozgu na druhý mozog pomocou imitácie. Taktiež postuloval, 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.


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):




Schématické znázornenie troch stupňov darwinovskej evolúcie pomocou hypotetického agenta s kognitívnym orgánom reprezentovaným neurónovou sieťou. Táto sieť je špecifikovaná fenotypom – chromozómom. V 1. stupni neexistuje spätná interakcia (učenie) medzi chromozómom a neurónovou sieťou, chromozóm „na tvrdo“ špecifikuje neurónovú sieť, zmeny v architektúre tejto siete sú možné len pomocou „neriadenej“ mutácie. V 2. stupni existuje už proces učenia, čiže môže dochádzať k zmenám neurónovej 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.

Cvičenie 4.8. Ako je definovaný m-chromozóm? Znázornite formálne Darwinovu evolúciu populácie obsahujúcej m-chromozómy.

Riešenie. 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*, $\alpha = (x, m)$



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).




Predmetom evolúcie v memetickom prístupe je populácia m-chromozómov.


Cvičenie 4.9. Ako je špecifikovaná horizontálna a vertikálna memetická interakcia?

Riešenie. 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 kvázináhonne 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



(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)



Cvičenie 4.10. Ako je špecifikovaný proces učenia (konštrukcia efektívneho fitness) pre m-chromozómy.

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

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

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

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

$$x = (00\#\#1\#0\#)$$

$$m = (11***0**)$$

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

Kde sme v šiestej polohe symbol # nahradili binárnym symbolom 0 z mému m .

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

$$d_{min} = \min_{y \in U(\hat{x})} (y - x_{opt})$$

Potom efektívne fitness priradené m-chromozómu α je určené formulou

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

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

Cvičenie 4.11. Ako môžeme usporiadať z pohľadu efektívnosti genetické algoritmy pri zahrnutí učenia a/alebo mémov?

Riešenie. GA môžu byť usporiadané do postupnosti s monotónnym zvyšovaním efektivity

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

