

Urychlení evolučních algoritmů pomocí RBF sítí

Lukáš Bajer

MFF UK
ÚI AVČR

29. dubna 2010

Obsah

- 1 **Optimalizace experimentů**
 - Genetické algoritmy: nástroj pro optimalizaci experimentů
 - Další vlastnosti náhradních modelů
- 2 **Regresní modely**
 - RBF síť
 - Náš model
- 3 **Experimentální výsledky**
 - Benchmark funkce
 - Data z výroby HCN

Obsah

- 1 **Optimalizace experimentů**
 - Genetické algoritmy: nástroj pro optimalizaci experimentů
 - Další vlastnosti náhradních modelů
- 2 **Regresní modely**
 - RBF sítě
 - Náš model
- 3 **Experimentální výsledky**
 - Benchmark funkce
 - Data z výroby HCN

Optimalizace experimentů

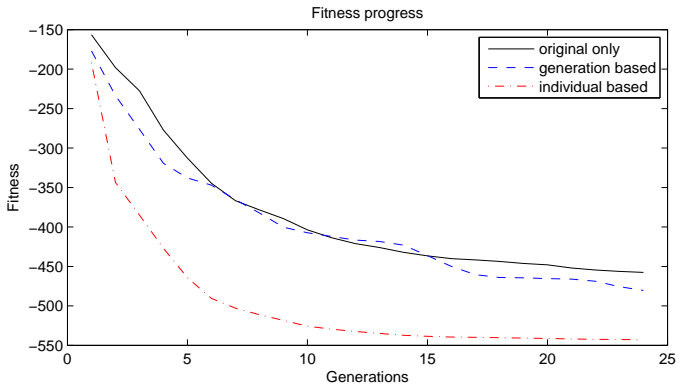
- drahé a/nebo časově náročné ohodnocení kvality navržených řešení
- spotřebované prostředky během optimalizace se měří především **počtem ohodnocení**
- nedůležité ukazatele jako
 - čas běhu algoritmu
 - počet iterací

Náhradní modely cílové funkce

Idea

- většinou ohodnotit pouze levným regresním modelem
- původní funkci použít jen občas
- aproximace původní fitness – většinou nepřesné
- velmi rychlé a levné
- učení z nově naměřených výsledků

Reklama: jak by to mohlo vypadat




Obsah

- 1 **Optimalizace experimentů**
 - Genetické algoritmy: nástroj pro optimalizaci experimentů
 - Další vlastnosti náhradních modelů
- 2 **Regresní modely**
 - RBF sítě
 - Náš model
- 3 **Experimentální výsledky**
 - Benchmark funkce
 - Data z výroby HCN

Genetické algoritmy (GA)

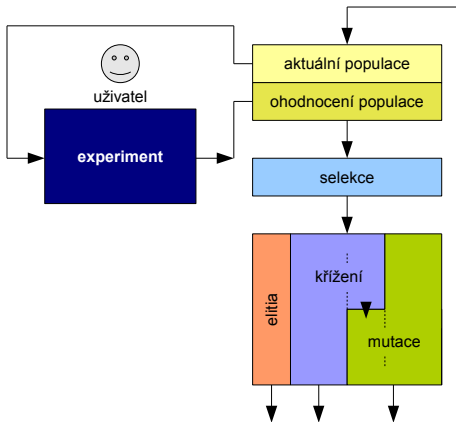
- metoda pro řešení obecných optimalizačních problémů
- inspirace v biologii (populace, křížení, mutace, ...)
- vhodné pro optimalizaci funkcí, které jsou
 - nespojitě
 - s vysokou dimenzí
 - kombinují spojitě a diskrétní proměnné



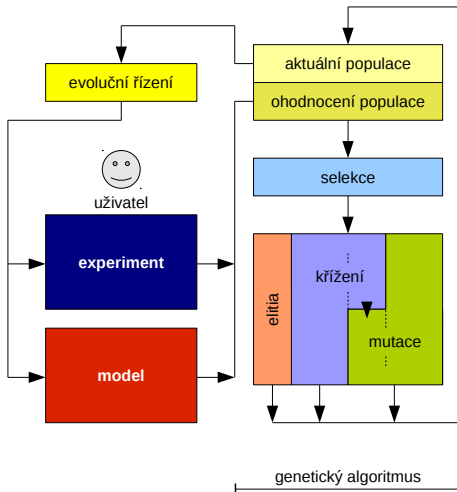
Empirické cílové funkce v GA

- 1 vyhodnocení empirické cílové funkce bývá **drahé** a **pomalé**
- 2 GA potřebují ke konvergenci **mnoho ohodnocení** cílovou funkcí

⇒ omezená použitelnost GA pro optimalizaci empirických funkcí



GA a náhradní model



Obsah

- 1 **Optimalizace experimentů**
 - Genetické algoritmy: nástroj pro optimalizaci experimentů
 - Další vlastnosti náhradních modelů
- 2 **Regresní modely**
 - RBF sítě
 - Náš model
- 3 **Experimentální výsledky**
 - Benchmark funkce
 - Data z výroby HCN

Evoluční řízení v GA

1 individuální

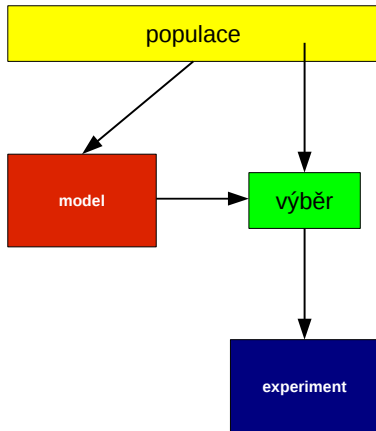
- GA udržuje větší populaci (často řádově)
- přesnou cílovou funkcí (experimentem) se ohodnotí jen část

2 generační

- GA ohodnocuje několik generací pouze modelem
- pak experimentem opraví nepřesnosti

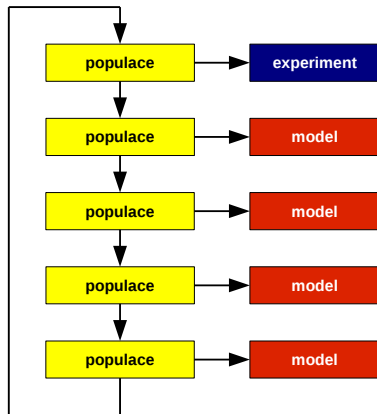
Individuální evoluční řízení

- 1 celá populace se ohodnotí modelem
- 2 její část se vybere pro přehodnocení experimentem
 - náhodný výběr
 - shlukování
 - nejlépe ohodnocené
 - s největší chybou

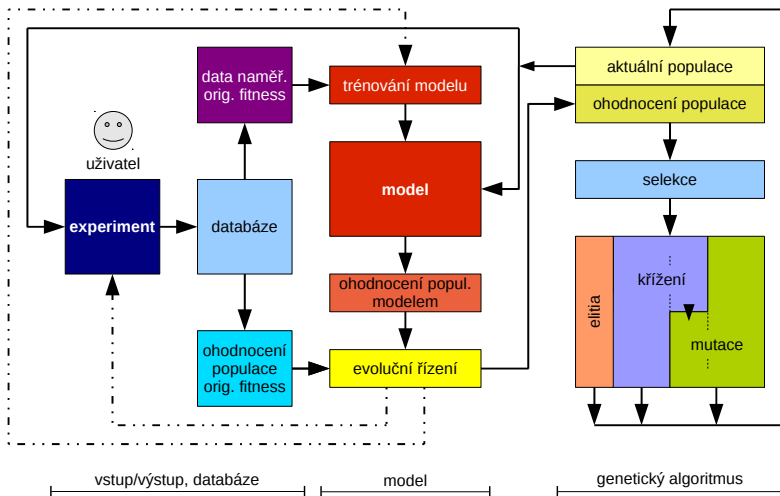


Generační evoluční řízení

- generace rozděleny do cyklů délky λ
- v každém cyklu se pouze v η generacích použije experiment a v dalších model, $\eta \leq \lambda$
- η se průběžně upravuje podle chyby modelu



Genetický algoritmus s náhradním modelem



Obsah

- 1 **Optimalizace experimentů**
 - Genetické algoritmy: nástroj pro optimalizaci experimentů
 - Další vlastnosti náhradních modelů
- 2 **Regresní modely**
 - RBF sítě
 - Náš model
- 3 **Experimentální výsledky**
 - Benchmark funkce
 - Data z výroby HCN

Regresní modely

- trénují se na základě omezeného počtu dat s naměřenou cílovou funkcí
- různé druhy:
 - polynomy
 - vícevrstvé perceptrony (BP síť)
 - **RBF síť**
 - opěrné vektory
 - ...

Regresní modely

naše požadavky:

- (relativně) rychlé učení
- co nejpřesnější, univerzální aproximační schopnost
- možnost doučování z nově získaných dat
- spojitě i diskrétní dimenze

Obsah


- 1 Optimalizace experimentů
 - Genetické algoritmy: nástroj pro optimalizaci experimentů
 - Další vlastnosti náhradních modelů
- 2 Regresní modely
 - RBF sítě
 - Náš model
- 3 Experimentální výsledky
 - Benchmark funkce
 - Data z výroby HCN

RBF sítě

RBF síť

$$f(\mathbf{x}) = \sum_{i=1}^g \pi_i f_i(\|\mathbf{x} - \mathbf{c}_i\|)$$

- pro jednoduchst 1-rozměrný případ: $f : \mathbb{R}^n \rightarrow \mathbb{R}$
- složeny z
 - g radiálních komponent f_i , pro každou
 - centrum $\mathbf{c}_i \in \mathbb{R}^n$
 - norma $\|\cdot\|$
 - případné další parametry
 - a jejich vah π_i




RBF sítě

- komponenty nejčastěji Gaussovské

$$f_i(\mathbf{x}) = g_i(\mathbf{x}; \mathbf{c}_i, \beta_i) = e^{-\beta \|\mathbf{x} - \mathbf{c}_i\|^2}$$

- trénování parametrů $\pi_i, \mathbf{c}_i, \beta_i$, $i = 1, \dots, g$ spojitou optimalizací (např. Levenberg-Marquardtovou metodou)
- inicializace parametrů například
 - centra \mathbf{c}_i náhodně z rovnoměrného rozložení
 - váhy π_i jako průměrná hodnota fitness z dat

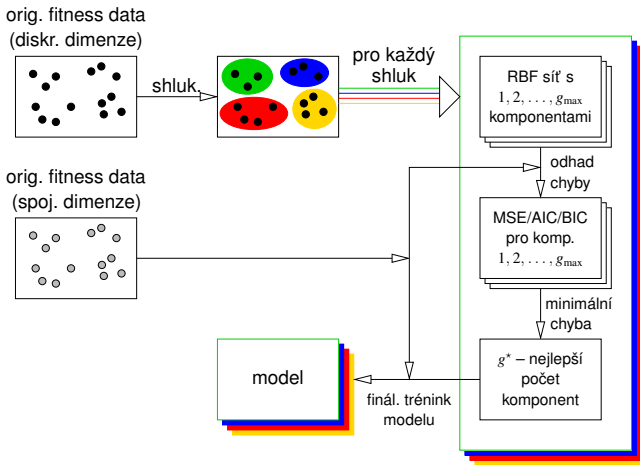
RBF sítě



Obsah

- 1 **Optimalizace experimentů**
 - Genetické algoritmy: nástroj pro optimalizaci experimentů
 - Další vlastnosti náhradních modelů
- 2 **Regresní modely**
 - RBF sítě
 - **Náš model**
- 3 **Experimentální výsledky**
 - Benchmark funkce
 - Data z výroby HCN

Trénování modelu




Hierarchické shlukování

- omezení minimální velikosti shluků

$$s_{\min} \geq \left\lceil \frac{k}{k-1} p \right\rceil$$

kde p je počet trénovaných parametrů a k stupeň křížové validace

- procházení dendrogramu odspodu, uřezávání dostatečně velkých shluků



Použití modelu

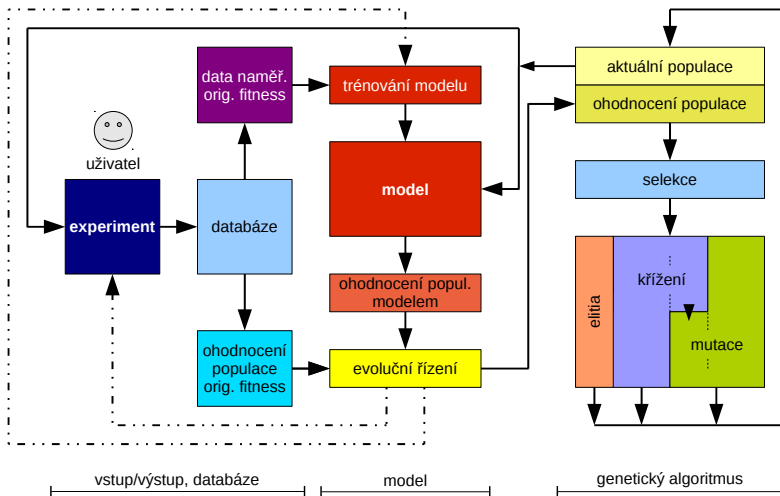
- výběr nejbližšího shluku podle diskretních proměnných $\mathbf{x}^{(d)}$

$$c = \arg \min_{j=1, \dots, m} \frac{1}{|\mathbf{N}_j|} \sum_{\mathbf{y} \in \mathbf{N}_j} d_{\text{DISCR}}(\mathbf{x}^{(d)}, \mathbf{y})$$

- dosazení parametrů c -té RBF sítě ($\pi_{c,i}, \mathbf{c}_{c,i}, \quad i = 1, \dots, g_c^*$) a spojitých proměnných $\mathbf{x}^{(c)}$ do rovnice sítě

$$\hat{y} = \sum_{i=1}^{g_c^*} \pi_{c,i} f_{c,i}(\|\mathbf{x}^{(c)} - \mathbf{c}_{c,i}\|).$$

Rekapitulace



Obsah

- 1 **Optimalizace experimentů**
 - Genetické algoritmy: nástroj pro optimalizaci experimentů
 - Další vlastnosti náhradních modelů
- 2 **Regresní modely**
 - RBF sítě
 - Náš model
- 3 **Experimentální výsledky**
 - Benchmark funkce
 - Data z výroby HCN

Obsah



- 1 **Optimalizace experimentů**
 - Genetické algoritmy: nástroj pro optimalizaci experimentů
 - Další vlastnosti náhradních modelů
- 2 **Regresní modely**
 - RBF síť
 - Náš model
- 3 **Experimentální výsledky**
 - **Benchmark funkce**
 - Data z výroby HCN

Experimentální výsledky

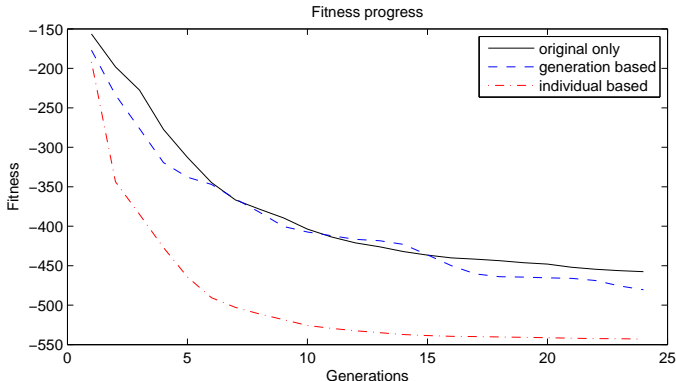
Úloha 1: Umělá benchmark funkce

- podobná chemickým empirickým (Valero a kol., 2009)
- snadno spočítatelná – možnost vyzkoušet na GA

Benchmark fitness: model



Benchmark fitness: genetický algoritmus



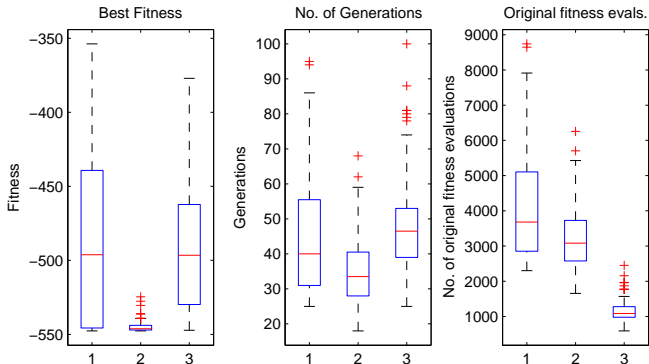
Obrázek: Fitness nejlepšího jedince v populaci v průběhu prvních 25 generací; průměrné výsledky ze 100 běhů genetického algoritmu

Benchmark fitness: genetický algoritmus

náhradní model (evol. řízení)	fitness nejlepšího nalez. jedince	počet generací	# ohodnocení experiment. fitness
–	–493.14	45.5	4188 (100%)
individuální	–542.02	27.2	2502 (59.7%)
generační	–498.85	46.7	1214 (28.9%)

Tabulka: průměrné výsledky ze 100 běhů genetického algoritmu

Benchmark fitness: genetický algoritmus



1 = bez modelu, 2 = individuální evol. říz., 3 = generační evol. říz.

Obsah



- 1 **Optimalizace experimentů**
 - Genetické algoritmy: nástroj pro optimalizaci experimentů
 - Další vlastnosti náhradních modelů
- 2 **Regresní modely**
 - RBF síť
 - Náš model
- 3 **Experimentální výsledky**
 - Benchmark funkce
 - Data z výroby HCN

Data z výroby HCN


Úloha 2: Data z výroby HCN

- výsledky z reálné aplikace GA
- pouze trénování modelu

Výroba HCN: model



Výroba HCN: model



Shrnutí

Přínos práce

- genetický algoritmus využívající náhradního modelu
- náhradní model s RBF sítěmi pro spojité i diskrétní hodnoty

Experimentální výsledky

- model v případě umělé testovací funkce ušetřil až 70 % vyhodnocení empirickou cílovou funkcí

Shrnutí

Děkuji za pozornost.

bajeluk (zavináč) seznam (tečka) cz

<http://bajeluk.matfyz.cz>