

Ing. Pavel KOPECKÝ, Ph.D.  
 ČVUT v Praze, Fakulta stavební

# Genetické algoritmy a jejich možné použití k optimalizaci budov

## Genetic algorithms and their potential use for optimization of buildings

Recenzent  
 Ing. Miloš Lain, Ph.D.

*Výpočtové modely jsou velmi důležité při navrhování budov. Podporují naše rozhodnutí a umožňují optimalizaci řešení. Optimalizační algoritmy na druhou stranu nejsou běžnou součástí softwarových nástrojů. Příspěvek se zabývá využitím genetických algoritmů (GA) pro optimalizaci energetického chování budov. Na třech příkladech je ukázáno využití vyvíjeného GA k optimalizaci jednoduché budovy.*

**Klíčová slova:** optimalizace, genetické algoritmy, navrhování budov

*Calculation models are of great importance in designing buildings. They support our decisions and enable problem optimization. On the other hand, optimization engines are still not a standard part of software packages. This paper deals with optimization of building performance by genetic algorithms (GA). Three sample optimization problems are solved by developed GA, increasing the number of optimization objectives and thus decreasing the chance to guess the combination of input parameters leading to optimal solution. It is finally proved that optimization by GA is a method generally applicable and easy-to-implement.*

**Keywords:** optimization, genetic algorithms, building design

Navrhování budov je vždy určitým kompromisem mezi často vzájemně si odporujícími tematickými oblastmi. Architekt se kromě estetického a funkčního řešení budovy a mnoha dalších dílčích problémů zabývá i vytápěním a chlazením (potřeba tepla na vytápění a chlazení, maximálními výkony vytápění a chlazení,...), pohodou vnitřního prostředí (teplota a vlhkost vnitřního vzduchu, koncentrace CO<sub>2</sub>,...), snížením solárních zisků, úrovní denního osvětlení, umělým osvětlením a také vazbou mezi budovou a technickými systémy. Problém návrhu budovy je velmi rozsáhlý a najít optimální řešení jistě není triviální. V dnešní době se běžně posuzuje kvalita návrhu budovy vhodnými výpočtovými modely.

Rozvoj počítačů a výpočtových modelů dnes umožňuje zabývat se i velmi složitými problémy. Optimalizace návrhu budovy se doposud v praxi považuje za pouhý uživatelský výběr nejlepší varianty z několika málo uvažovaných variant. Jde o postup intuitivní, který někdy může vést k překvapivě dobrým výsledkům (při dostatečných zkušenostech a intuici). Budovy jsou nicméně velmi složité systémy s mnoha proměnnými, s mnoha zpětnými vazbami, mnoha okrajovými podmínkami a mnoha různými a často protichůdnými požadavky na jejich výsledné chování. Návrh budovy je obtížnou *vícekritériální* úlohou.

Metody matematické optimalizace mohou v dnešní počítačové době pomoci uživateli nejen k optimalizaci návrhu, ale i k lepšímu pochopení problému samotného. Genetické algoritmy (GA) náleží mezi stochastické optimalizační metody a jsou obecně považovány za velmi vhodné k řešení *vícekritériálních* optimalizačních problémů. Rozsah využití GA je nicméně velmi široký. V oblasti stavební fyziky byly GA například použity pro validaci simulačního modelu budovy, viz [1]. Dále mohou být využity při návrhu architektury a vah neuronových sítí a jistě existují i další možnosti využití.

### VÍCEKRITÉRIÁLNÍ OPTIMALIZACE

Vícekritériální optimalizace formálně představuje hledání optimálních hodnot (zaznamenejme, že zatím není definováno, co optimální znamená) vektoru  $k$  účelových funkcí:

$$\mathbf{f}(\mathbf{x}) = (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_k(\mathbf{x})) \quad (1)$$

kde  $\mathbf{x}$  je vektor  $n$  optimalizačních proměnných. Soustava přirozených omezujících podmínek (spodní a horní meze optimalizačních proměnných) vymezuje návrhovou oblast. Další omezující podmínky (ve tvaru rov-

ností nebo nerovností) vymezují z návrhové oblasti přípustnou oblast. Metody matematické optimalizace více či méně „inteligentním“ způsobem prozkoumávají přípustnou oblast a hledají optimální řešení.

Jelikož je optimalizační problém určen hodnotami několika účelových funkcí, nelze vždy jednoznačně rozhodnout, které řešení je lepší než druhé. Je pouze možné nalézt množinu kompromisních řešení, tzv. Paretovu<sup>1)</sup> množinu nedominantních řešení. Úkolem optimalizačního algoritmu je najít tuto množinu pokud možno co nejmenším počtem rovnoměrně rozmístěných bodů.

Zvláštním případem *vícekritériální* optimalizace je *jednokritériální* optimalizace. Hodnoty jediné účelové funkce je možné jednoznačně seřadit, a je tedy možné nalézt jediné optimální řešení (*extrém* účelové funkce).

### GENETICKÝ ALGORITMUS

V přírodě s větší pravděpodobností přežijí pouze úspěšní jedinci, kteří následně zplodí generaci svých potomků. Napodobování tohoto přírodního principu je základní myšlenkou GA. Graficky velmi názorně zpracovaný interaktivní tutoriál o genetických algoritmech nabízí [2]. Odkazy na další literaturu o GA jsou uvedeny například v [3].

K popisu algoritmu se používá terminologie z biologie. Řetězec genů se nazývá chromozóm. Každý gen vyjadřuje optimalizační proměnnou, například tloušťku tepelné izolace nějaké konstrukce, časovou konstantu zóny, koeficient stínění určitého okna apod. Každý chromozóm jednoznačně vyjadřuje jedno možné řešení problému.

Algoritmus začne z náhodně vytvořené počáteční populace o  $N$  jedincích (jedinec = kódovaná verze chromozómu). Dokud není splněna podmínka ukončení algoritmu, cyklicky pak probíhají následující kroky (viz také obr. 1 a 2):

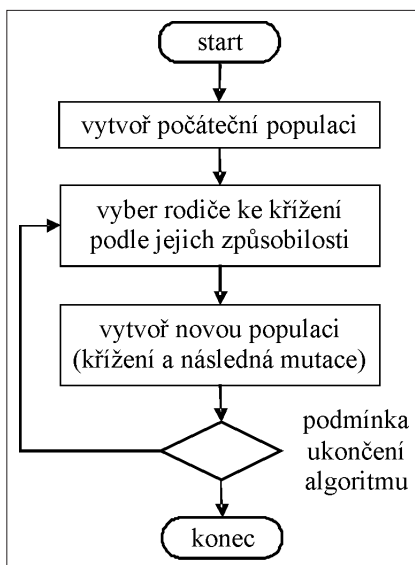
1. ohodnocení způsobilosti (síly)<sup>2)</sup> každého jedince z populace k další reprodukci;

<sup>1)</sup> Vilfredo Pareto (1848–1923) – italský ekonom a sociolog, proslul zejména formulací *Paretova optima* (představuje stav, kdy již není možné zlepšit jedno kritérium bez současného zhoršení kritéria druhého) a *Paretova principu* („20 % populace vlastní 80 % majetku“).


<sup>2)</sup> v angličtině se používá termín *fitness*

	$U_{kon}$	$U_w$	$F_{gla}$	$A_p/A$	$U_{em}$
<b>Výběr</b>					
rodič 1	0,15	1,00	0,25	0,40	0,19
rodič 2	0,18	0,70	0,07	0,15	0,21
<b>Křížení</b>					
	0,15	1,00	0,25	0,40	
	0,28	0,70	0,07	0,15	
<b>Mutace</b>					
			0,06		
	0,15	0,70	0,07	0,15	
	0,28	1,00	0,25	0,40	
<b>Potomci</b>					
potomek 1	0,15	0,70	0,06	0,15	0,17
potomek 2	0,28	1,00	0,25	0,40	0,32

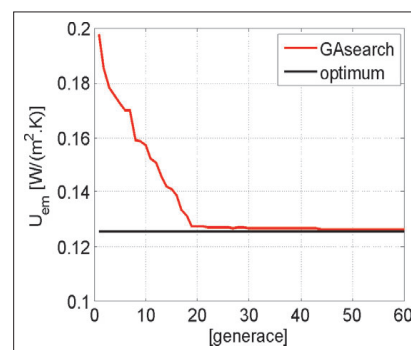
Obr. 1 Výběr, křížení, mutace (genetické operátory) – ilustrace k prvnímu řešenému příkladu (minimalizace průměrného součinitele prostupu tepla)



Obr. 2 Vývojový diagram genetického algoritmu



Obr. 3 Vstupní údaje do modelu výpočtu průměrného součinitele prostupu tepla



Obr. 4 Vývoj nejlepšího jedince z populace během jednotlivých generací a porovnání s optimálním řešením

- výběr rodičů ke křížení – s větší pravděpodobností se vyberou lepší jedinci (podle jejich způsobilosti), např. výběr napodobením kuličky na ruletě (náhodné číslo od nuly do jedné), kdy větší výšeč z kruhu rulety zabírají lépe hodnocení rodiče, při výběru je vhodné použít tzv. elitismu, kdy pár nejlépe hodnocených rodičů je do nové populace nakopírován beze změny (používá se pro zlepšení konvergence algoritmu);
- křížení – tvorba potomků z rodičů, rozdělení chromozómu v určitém místě nebo místech (místo opět voleno náhodně) a zkombinování obou dědičných informací, vytvoření dvou nových chromozómů;
- mutace – velmi malá část genů nových chromozómů je uměle změněna (při binárním kódování záměna nuly za jedničku, nebo přičtení či odečtení velmi malého čísla při kódování reálnými čísly);
- z potomků se vytvoří nová populace;
- stará populace se nahradí novou a cyklus probíhá znovu od bodu 1.

## ŘEŠENÉ PŘÍKLADY

Pro účely řešení následujících příkladů byl vytvořen vlastní Matlab kód, což je výhodné zejména pro hlubší pochopení GA. V Matlabu také existují volně využitelné toolboxy pro genetické algoritmy, viz [4].

### Jednokriteriální optimalizace

Pro testování a vývoj vlastního genetického algoritmu byly využity dvě jednoduché jednokriteriální úlohy – minimalizace průměrného součinitele prostupu tepla obálky budovy a minimalizace potřeby tepla na vytápění budovy.

#### Průměrný součinitel prostupu tepla obálky budovy

##### □ Model

Průměrný součinitel prostupu tepla  $U_{em}$  se vypočítá jako vážený průměr přes plochy

$$U_{em} = U_{kon} \left( \frac{A - A_w}{A} \right) + U_w \left( \frac{A_w}{A} \right) \quad (2)$$

kde

$U_{em}$  je průměrný součinitel prostupu tepla obálky budovy, [W/(m<sup>2</sup>.K)];  
 $U_{kon}$  součinitel prostupu tepla konstrukcí (všech neprůhledných částí – stěn, střechy, podlahy, do hodnoty  $U_{kon}$  jsou dále započteny vliv tepelných mostů a vliv zeminy), [W/(m<sup>2</sup>.K)];

$U_w$  součinitel prostupu tepla oken, [W/(m<sup>2</sup>.K)];

$A_w$  plocha oken, [m<sup>2</sup>];

$A$  celková ochlazovaná plocha vypočtená z venkovních rozměrů, [m<sup>2</sup>].

Aby lépe vynikl vliv geometrie budovy na hodnotu  $U_{em}$ , byl vzorec přepsán do jiného tvaru

$$U_{em} = U_{kon} (1 - F_{gla} F_{fas}) + U_w (F_{gla} F_{fas}) \quad (3)$$

kde

$F_{gla}$  je zastoupení plochy oken v ploše fasády  $F_{gla} = A_w/A_{fas}$  (předpokladem je, že okna jsou umístěna pouze ve fasádách), [-];

$F_{fas}$  zastoupení plochy fasády v celkové ochlazované ploše,  $F_{fas} = A_{fas}/A$ , [-].

Pro kvádr (může jít i o členitější objekt, důležitá je podmínka stejných ploch podlahy a střechy) lze odvodit, že:

$$F_{fas} = 1 - \frac{2A_p}{A} \quad (4)$$

kde

$A_p$  je zastavěná plocha, [m<sup>2</sup>].

Průměrný součinitel prostupu tepla obálky budovy je tedy ovlivněn tepelnou izolační kvalitou jednotlivých prvků na systémové hranici budovy vyjádřené hodnotami součinitelů prostupu tepla konstrukcí a oken. Dále ho ovlivňují dva geometrické parametry – poměr plochy oken a plochy fasád, poměr plochy fasád a celkové ochlazované plochy obálky budovy.

##### □ Formulace optimalizačního problému

Úkolem GA je hledat optimální (minimální)  $U_{em}$  na oblasti vymezené meze- mi dle tab. 1.

Tab. 1 Proměnné v optimalizaci

proměnná	$U_{kon}$	$U_w$	$F_{gla}$	$A_p/A$
min	0,12	0,7	0,05	0,15
max	0,40	1,8	1,0	0,40

##### □ Optimální řešení

Vzorec (3) vyjadřuje to, co intuitivně cítíme. Nejnižší průměrný součinitel prostupu tepla bude mít budova s nejnižšími možnými souči-

niteli prostupu tepla konstrukcí a oken, nejnižším možným zastoupením plochy oken v ploše fasády a nejvyšším možným zastoupením plochy podlahy v celkové ploše obálky:  $\min(U_{kon}, U_w, F_{gla})$  a zároveň  $\max(A_p/A)$ . Bodový bytový dům s vysokým zastoupením fasád (a tedy i oken) v ochlazené ploše obálky nedosáhne při totožné tepelné izolační kvalitě stejného  $U_{em}$  jako například supermarket, tj. přízemní objekt s malým zastoupením fasád v ochlazené ploše. Protože minimální hodnota poměru plochy oken k ploše fasády je v příkladu zadána poměrně nízká, bude se optimální řešení příkladu blížit k minimální hodnotě součinitele prostupu tepla konstrukcí.

Na obr. 4 je viditelná počáteční velmi rychlá konvergence GA k optimálnímu řešení. Zpomalení konvergence souvisí s vymizením různorodosti populace. Pouze změny jednotlivých genů vlivem mutací pak zajišťují pomalou konvergenci k optimálnímu řešení.

**Potřeba tepla na vytápění**

**Model**

Výpočet potřeby tepla na vytápění probíhal měsíční metodou podle [5] a pravidel výpočtu z [6]. Přenos tepla zeminou byl vypočten zjednodušeným postupem využitím redukčního činitele  $b_{soil}$ .

**Formulace optimalizačního problému:**

Úkolem GA je hledat optimální (minimální) měrnou potřebu tepla na vytápění (označena jako  $f_1$ ) na oblasti vymezené mezemi dle tab. 2. Je daný tvar objektu (viz obr. 5) a je dáno okolí objektu (objekt bez stínění na „zelené louce“). Konstantami v optimalizaci jsou: rozměry objektu  $a, b$ , počet podlaží  $n_p$ , tloušťka obvodových stěn  $t_{ew}$ , počet osob  $n_{os}$ , účinnost zpětného získávání tepla  $\eta$ , redukční činitel (vliv zeminy)  $b_{soil}$  a faktory stínění oken na jednotlivých fasádách  $F_{shS}, F_{shW}, F_{shE}, F_{shN}$ . Optimalizační proměnné tvořící jedince jsou: časová konstanta zóny  $\tau$ , součinitele prostupu tepla střechy  $U_{str}$ , fasády  $U_{fas}$ , podlahy na zemině  $U_p$ , oken  $U_w$ , celková propustnost sluneční energie zasklením  $g$ , zastoupení plochy zasklení v ploše okna  $F_{frame}$  a zastoupení plochy oken v jednotlivých fasádách  $F_{gla}$ .


**Odhad optimálního řešení**

V této úloze jsou procenta prosklení jedinými parametry, u kterých je obtížné odhadovat jejich vliv. Tyto parametry totiž ovlivňují jak tepelné ztráty, tak tepelné zisky objektu, a proto je reakce modelu na jejich změnu těžko předvídatelná. Všechny ostatní vstupní údaje ovlivňují vždy jen jednu složku tepelné bilance. Optimální řešení proto je:  $\max(\tau, g, F_{frame})$  a zároveň  $\min(U_{str}, U_{fas}, U_p, U_w)$  a zároveň ? ( $F_{glaS}, F_{glaW}, F_{glaE}, F_{glaN}$ ).

**Optimální řešení**

Tab. 3 ukazuje výsledky optimalizace pro dva rozměrově stejné domy s rozdílnou kvalitou obvodových konstrukcí. U obou optimalizačních problémů bylo výhodné maximalizovat plochu oken jižní

fasády a minimalizovat plochu oken severní fasády. Oba problémy však vykazují různá optima v zastoupení oken na západní a východní fasádě. V případě problému P1 („pasivní dům“) bylo nejvýhodnější minimalizovat plochu západních a východních oken. Naopak v případě problému P2 („nízkoenergetický dům“ s okny v pasivním standardu) byl optimální poměr prosklení západní a východní fasády 77 % (viz tab. 3).



Obr. 5 Některé vstupní údaje do modelu výpočtu potřeby tepla na vytápění

**Diskuze výsledků**

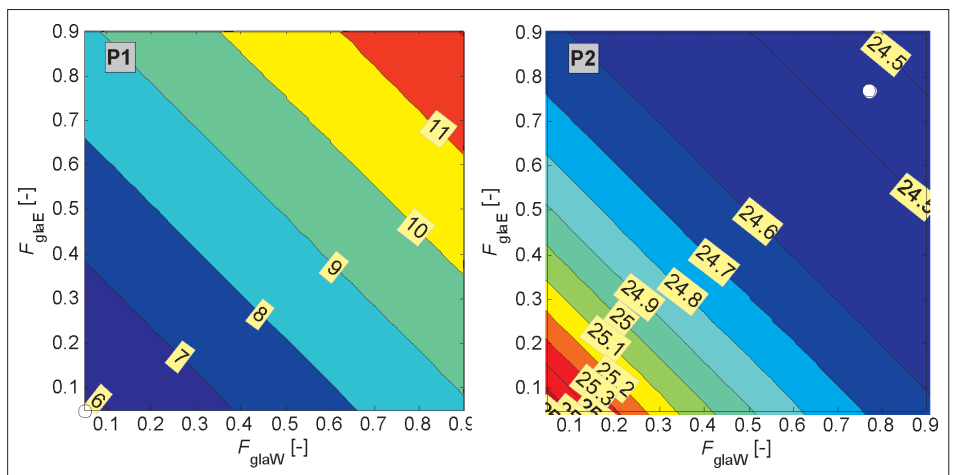
Ve výše uvedených příkladech jsme našli jako nejvýhodnější určitou hodnotu prosklení západní a východní fasády. Výsledky vyvolávají otázku, jak moc se na ně můžeme spoléhat. Proto byla reakce modelu studována na případech, které ukotvily hodnoty optimalizačních proměnných do jejich optimálních hodnot (viz tab. 3). Jedinými proměnnými zůstaly poměry prosklení západní a východní fa-

Tab. 2 Konstanty a proměnné v optimalizaci, P1, P2 jsou dvě varianty optimalizačního problému

	Konstanta	$a$	$b$	$n_p$	$t_{ew}$	$n_{os}$	$\eta$	$b_{soil}$	$F_{shS}$	$F_{shW}$	$F_{shE}$	$F_{shN}$
P1		10	10	2	0,35	4	0,8	0,9	0,9	0,9	0,9	0,9
P2		10	10	2	0,35	4	0	0,9	0,9	0,9	0,9	0,9
	Proměnná	$\tau$	$U_{str}$	$U_{fas}$	$U_p$	$U_w$	$g$	$F_{frame}$	$F_{glaS}$	$F_{glaW}$	$F_{glaE}$	$F_{glaN}$
P1	min	24	0,12	0,12	0,12	0,70	0,40	0,65	0,05	0,05	0,05	0,05
P1	max	100	0,20	0,20	0,20	1,00	0,60	0,72	0,90	0,90	0,90	0,90
P2	min	24	0,30	0,30	0,30	0,70	0,40	0,65	0,05	0,05	0,05	0,05
P2	max	100	0,40	0,40	0,40	1,00	0,60	0,72	0,90	0,90	0,90	0,90

Tab. 3 Optimální řešení pro dva optimalizační problémy, GA označuje řešení získané vyvinutým genetickým algoritmem, OpT označuje řešení získané řešením v optimalizačním toolboxu Matlabu (použitý řešitel „fmincon“)

		$\tau$	$U_{str}$	$U_{fas}$	$U_p$	$U_w$	$g$	$F_{frame}$	$F_{glaS}$	$F_{glaW}$	$F_{glaE}$	$F_{glaN}$	$f_1$
GA	P1	100	0,12	0,12	0,12	0,7	0,6	0,72	0,90	0,05	0,07	0,05	<b>5,88</b>
	P2	100	0,30	0,30	0,30	0,7	0,6	0,72	0,90	0,70	0,88	0,05	<b>24,49</b>
OpT	P1	100	0,12	0,12	0,12	0,7	0,6	0,72	0,90	0,05	0,05	0,05	<b>5,81</b>
	P2	100	0,30	0,30	0,30	0,7	0,6	0,72	0,90	0,77	0,77	0,05	<b>24,49</b>



Obr. 6 Měrná potřeba tepla na vytápění jako funkce dvou parametrů  $F_{glaW}$  a  $F_{glaE}$ , ostatní parametry byly ukotveny v optimálních hodnotách dle tab. 3, optimum je vyznačeno bílým bodem (viz také tab. 3)

sády. Na obr. 6 je zobrazena výsledná potřeba tepla na vytápění jako funkce těchto dvou poměrů. V případě problému P1 vyvolá změna obou poměrů prosklení přiměřenou změnu v potřebě tepla na vytápění (obr. 6 – vlevo). V případě problému P2 vyvolá změna obou poměrů prosklení velmi malou změnu v potřebě tepla na vytápění (obr. 6 – vpravo). U problému P2 je tedy téměř jedno, jak velká budou okna na západní či východní fasádě. Tato dílčí minis studie poukazuje na obecnou potřebu propojení optimalizačních algoritmů s citlivostní analýzou.

Jednokriteriální optimalizace může vést k zavádějícím výsledkům. Například nikdo z rozumných architektů by nedělal 100% zasklení plochy jižní fasády z důvodu rizika přehřívání budovy. Proto se následující část článku věnuje vícekriteriální optimalizaci.

## Vícekritériální optimalizace

### Metoda vah

Častým přístupem k řešení vícekritériálního optimalizačního problému je převod na jednokriteriální optimalizační problém:

$$f(\mathbf{x}) = \sum_i^k w_i f_i(\mathbf{x}) \quad (5)$$

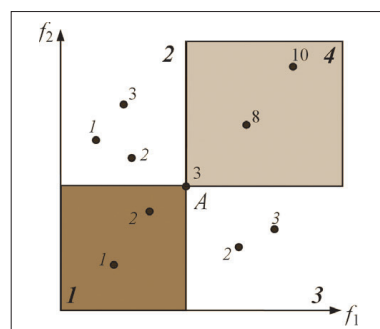
kde

$w_i$  jsou váhy vyjadřující relativní důležitost jednotlivých kritérií ( $\sum w_i = 1$ );  
 $f_i$  jsou jednotlivé účelové funkce (v případě, že nemají stejné jednotky, je vhodná normalizace účelových funkcí vzhledem ke zvolenému nejlepšímu možnému řešení).

Postupnou změnou hodnot vah lze získat Paretovo množinu (v případě dvou kritérií se jedná o křivku, v případě tří kritérií se jedná o povrch). Výhodou postupu je jeho jednoduchost a snadná implementace. Velmi dobře se hodí pro dvoukritériální případně tříkritériální optimalizační problémy, protože nutný počet různých hodnot vah k získání Pareta je přiměřený. Algoritmus pro jednokriteriální GA se tedy pouze zopakuje vícekrát za sebou s různými hodnotami vah.

### Přístup založený na Pareto dominanci

Problémem využití GA k řešení vícekritériálního problému je způsob ohodnocení jedince. Jedince nelze totiž jednoduše seřadit jako je tomu u jednokriteriální optimalizace. Jednou z možností je ohodnocení jedince na základě jeho dominance nad ostatními jedinci. Termín dominance vysvětluje obrázek 7.



Grafická interpretace dominance:

- Jedinci z oblasti 1 jsou dominantní nad jedincem A.
- Jedinci z oblastí 2,3 jsou na stejné úrovni jako A.
- Jedinec A je dominantní nad jedinci z oblastí 4.

Obr. 7 Ranking založený na dominanci jedince, čísla vedle bodů jsou hodnoty rank


Tab. 4 Problém P3 – optimální řešení pro různá nastavení vah (pozn.: GA nemusí vždy najít opravdové optimum. Předpokládá se ovšem, že získaná řešení jsou blízko těm skutečně optimálním.

$w_1$	$w_2$	$\tau$	$U_{str}$	$U_{fas}$	$U_p$	$U_w$	$g$	$F_{frame}$	$F_{glas}$	$F_{glaW}$	$F_{glaE}$	$F_{glaN}$	$f_1$	$f_2$
0	1,0	100	0,40	0,40	0,40	1,0	0,4	0,65	0,05	0,05	0,05	0,05	85,2	0,0
0,1	0,9	100	0,12	0,16	0,12	1,0	0,4	0,65	0,05	0,05	0,05	0,05	25,8	1,1
0,2	0,8	100	0,12	0,12	0,12	0,7	0,4	0,65	0,05	0,05	0,05	0,05	18,2	2,3
0,3	0,7	100	0,12	0,12	0,12	0,7	0,4	0,65	0,05	0,05	0,05	0,05	18,2	2,3
0,4	0,6	100	0,12	0,12	0,12	0,7	0,4	0,65	0,05	0,05	0,05	0,05	18,2	2,3
0,5	0,5	100	0,12	0,12	0,12	0,7	0,4	0,65	0,05	0,05	0,05	0,05	18,2	2,3
0,6	0,4	100	0,12	0,12	0,12	0,7	0,5	0,65	0,05	0,05	0,05	0,05	17,2	3,7
0,7	0,3	100	0,12	0,12	0,12	0,7	0,6	0,72	0,09	0,05	0,05	0,05	14,7	8,6
0,8	0,2	100	0,12	0,12	0,12	0,7	0,6	0,72	0,20	0,05	0,05	0,05	12,3	15,9
0,9	0,1	100	0,12	0,12	0,12	0,7	0,6	0,72	0,46	0,05	0,05	0,05	8,7	37,7
1,0	0	100	0,12	0,12	0,12	0,7	0,6	0,72	0,9	0,05	0,05	0,05	5,8	79,5


V literatuře lze nalézt mnoho přístupů k ohodnocení způsobilosti jedince; jednou z možností je ranking podle [7]:

$$\text{rank}(x_i, t) = 1 + p_i \quad (6)$$

kde  $x_i$  je jedinec v generaci  $t$ , jemuž dominuje  $p_i$  jedinců. Všichni jedinci, jimž nedominuje žádný jiný jedinec, mají hodnotu rank rovnou jedna. Tento způsob ohodnocení penalizuje jedince z oblastí, v kterých je vyšší úroveň informace (hustější oblasti) a pomáhá tak udržet dobrou různorodost populace.



Obr. 8 Paretovo optimum problému P3 (metoda vah)



Obr. 9 Paretovo optimum problému P3 (přístup založený na Pareto dominanci) – černé body zobrazují všechny hodnoty z jednotlivých generací populace



### Potřeba tepla na vytápění a chlazení

#### □ Model

Pro výpočty potřeby tepla na vytápění byla využita měsíční metoda podle [5] a pravidla výpočtu z [6]. Přenos tepla zeminou je vypočten zjednodušeným postupem využitím redukčního činitele  $b_{\text{soil}}$ . Pro výpočet potřeby tepla na chlazení byla využita měsíční metoda podle [5]. Požadovaná teplota v budově byla 27 °C. Okna bez stínění byla uvažována i pro výpočty potřeby tepla na chlazení.

#### □ Formulace optimalizačního problému

Předchozí příklad, který uvažoval pouze potřebu tepla na vytápění, přibírá i druhé kritérium, potřebu tepla na chlazení (označeno jako P3). Konstanty a optimalizační proměnné se uvažují podle Tabulky 2 (spodní mez z P1, horní mez z P2).

#### □ Odhad optimálního řešení

Úloha se stává obtížnější pro intuitivní odhad. Snad lze předpokládat, že varianty s nejvyšší potřebou tepla na vytápění budou mít nízké nároky na chlazení a naopak.

#### □ Optimální řešení

Optimalizační problém byl řešen oběma představenými postupy (váhování účelových funkcí, Pareto přístup). Účelové funkce jsou označeny:  $f_1$  – měrná potřeba tepla na vytápění [ $\text{kWh}/(\text{m}^2 \cdot \text{a})$ ],  $f_2$  – měrná potřeba tepla na chlazení [ $\text{kWh}/(\text{m}^2 \cdot \text{a})$ ], potřeby jsou vztaženy na  $\text{m}^2$  klimatizované podlahové plochy. Výsledky z optimalizace jsou zobrazeny na obr. 8 a 9. Pareto optimum může sloužit jako vodítko pro rozhodnutí, kterou z variant opravdu považovat za optimální. Dobrou variantou by v tomto případě byla varianta s měrnou potřebou tepla na vytápění 20  $\text{kWh}/(\text{m}^2 \cdot \text{rok})$ , protože by současně nevedla k dramatickému navýšení nároků na chlazení.

## ZÁVĚRY

Optimalizace genetickým algoritmem je univerzálním postupem využitelným i v oblasti stavební fyziky. Algoritmus není složitý na pochopení ani na naprogramování a může tak být dobrým pomocníkem při hledání co nejlepších řešení. K výsledkům optimalizace je ovšem nutné přistupovat obezřetně. Existuje problém nejistoty výpočtového modelu. Bez dobrého a ověřeného výpočtového modelu je elegantní krása genetických algoritmů k ničemu. Výsledky z optimalizací jednoduše nejsou použitelné, protože model dostatečně dobře nepopisuje realitu. Existuje i problém nesmyslných úloh. Velmi zá-

leží na samotné formulaci optimalizační úlohy. Optimalizační problém je často tak složitý, že neumíme dobře popsat všechny účelové funkce ani všechny okrajové podmínky. Vhodná formulace optimalizačního problému je velkým uměním. Algoritmus vždy jen hledá daným postupem na přípustné oblasti a neměl by nahrazovat lidský rozum a intuici.

GA jsou obecně velmi silné a jednoduše využitelné zejména ve fázi koncepčního návrh budov (předvýběr za použití jednoduchých výpočtových modelů). Prakticky se osvědčilo převést optimalizační problém na jednokritériální (metoda vah) a na něj použít GA. Pareto přístup nevedl vždy ke spolehlivému vyhledání Pareto optima. Důvodem byla nedokonalost vyvinutého algoritmu (rychlá ztráta diversity populace). Pro zlepšení by bylo potřeba dalšího studia GA.

Určitou otázkou je vhodnost GA pro simulační výpočty, které obecně jsou náročnější na výpočtový čas. Využití genetického algoritmu zřejmě bude narážet na požadavek získat výsledky v reálném čase. Protože je potřeba celé populace řešení a generací se musí vystřídat mnoho, mohou i jednoduché simulační modely znamenat velmi dlouhé čekání na výsledek. Například pokud jedna simulace trvá 10 s, v populaci máme 20 jedinců, a potřebujeme 500 generací,  $10 \times 20 \times 500 \text{ s} =$  přibližně 27,8 hodin). Urychlení je nejspíše možné paralelními výpočty na více procesorech. I takového použití „hrubé síly“ je dnes možné.

#### Poděkování:

Tento výsledek byl získán za finančního přispění MŠMT ČR, projekt 1M0579, v rámci činnosti výzkumného centra CIDEAS.

Kontakt na autora: pavel.kopecky@fsv.cvut.cz

#### Použité zdroje:

- [1] Lauret, P., Boyer, H., Riviere, C., Bastide, A., A genetic algorithm applied to the validation of building thermal models, Energy and Buildings, 2005, Volume 37, Issue 8, s. 858–866
- [2] tutoriál dostupný na: <http://www.obitko.com/tutorials>
- [3] Coello, C., *An empirical study of evolutionary techniques for multiobjective optimization in engineering design*, dissertation thesis, New Orleans: Tulane University, 1996
- [4] seznam dostupný na: [http://www.geatbx.com/ea\\_matlab.html](http://www.geatbx.com/ea_matlab.html)
- [5] ČSN EN ISO 13790:2009
- [6] TNI 730329:2009
- [7] Fonseca, C., M., Fleming, P., J., Genetic algorithms for multiobjective optimization: formulation, discussion and generalization, In: Proc, 5<sup>th</sup> Int, Conf, Genetic Algorithms, s. 416–423, 1993 ■